

# **Entwicklung eines Algorithmus zur Prädiktion eines innerstädtischen Fahrstreifenwechsels**

Am Fachbereich Maschinenbau  
an der Technischen Universität Darmstadt

zur

Erlangung des akademischen Grades eines Doktor-Ingenieurs (Dr.-Ing.)

genehmigte

## **DISSERTATION**

vorgelegt von

**Dipl.-Ing. Jens Heine**

aus Göttingen

Berichterstatter:

Prof. Dr.-Ing. Ralph Bruder

Mitberichterstatter:

Prof. Dr.-Ing. Ulrich Konigorski

Tag der Einreichung:

30. Juni 2017

Tag der mündlichen Prüfung:

29. November 2017

Darmstadt 2017

D17

---

Please refer to:

URN: [urn:nbn:de:tuda-tuprints-75440](https://nbn-resolving.org/urn:nbn:de:tuda-tuprints-75440)

URI: <http://tuprints.ulb.tu-darmstadt.de/id/eprint/7544>

This Document is provided by tuprints,  
e-publishing-service of Technische Universität Darmstadt  
<http://tuprints.ulb.tu-darmstadt.de/>

Veröffentlicht unter CC BY-NC-ND 4.0 International  
<https://creativecommons.org/licenses/>

---

## Danksagung

Die vorliegende Arbeit entstand während meiner Tätigkeit als Doktorand bei der Adam Opel AG im Rahmen der Zusammenarbeit mit dem Institut für Arbeitswissenschaft der Technischen Universität Darmstadt in der Forschungsinitiative UR:BAN.

Mein besonderer Dank gilt Herrn Prof. Dr.-Ing. Ralph Bruder für die Unterstützung als Doktorvater, für das mir entgegengebrachte Vertrauen während meines Promotionsvorhabens und alle fachlichen Anregungen und Diskussionen, die wir während dieser Zeit geführt haben.

Herrn Prof. Dr.-Ing. Ulrich Konigorski danke ich für die freundliche Übernahme des Korreferats und den fachlichen Austausch im Rahmen meines Promotionsvorhabens.

Ich bedanke mich exemplarisch bei Frank Bonarens, dem verantwortlichen Projektleiter der UR:BAN Forschungsinitiative bei Opel und Thomas Schramm, meinem Betreuer während der Doktorandenzeit. Mein Dank gilt ebenfalls der Doktorandengruppe bei Opel für die stets freundschaftliche und fachlich anregende Gemeinschaft. Weiterhin gilt der Dank allen Kollegen bei Opel und am Institut für Arbeitswissenschaft, welche mich in meinem Promotionsvorhaben unterstützt haben und jederzeit für einen fachlichen Austausch und Unterstützung zur Verfügung standen. Eure offene und ehrliche Art zu diskutieren und der herzliche Umgang miteinander werden mir immer in Erinnerung bleiben.

Herzlichen Dank an meinen Projektkollegen Ingmar Langer. Unsere Zusammenarbeit im UR:BAN Projekt, bei der gemeinsamen Durchführung unserer Probandenstudie sowie in allen Themen unserer Promotion, haben sowohl fachlich als auch darüber hinaus wesentlich zum Gelingen meiner Dissertation beigetragen.

Ich danke allen Studenten, welche mich im Rahmen ihrer Abschlussarbeiten, als Praktikant bei Opel oder in der Studiendurchführung unterstützt und einen wesentlichen Teil zu dieser Arbeit beigetragen haben. In erster Linie bei Michael Sylla, Isabell Krämer, Philipp Kunz, Igor Achieser und Shubham Dosi.

Meiner Familie möchte ich für die Unterstützung während des gesamten Promotionsvorhabens danken. Insbesondere meiner Mutter bedarf dabei außergewöhnlicher Dank für die Unterstützung meines bisherigen Lebens als Voraussetzung und zur Ermöglichung dieser Dissertation. Ebenfalls gilt meiner Freundin Katja ein besonderer Dank für ihre Unterstützung und Liebe während des Promotionsvorhabens.

---

## Zusammenfassung

Autofahren ist ein essentieller Bestandteil der individuellen Mobilität, birgt aber aufgrund menschlichen Fehlverhaltens eine hohe Unfallgefahr. Fahrerassistenzsysteme zur aktiven Sicherheit tragen in aktuellen Personenkraftwagen zu einer Reduktion von Unfällen im Straßenverkehr bei, da sie den Fahrer bei der Bewältigung unfallträchtiger Situationen unterstützen. Die Wirksamkeit von warnenden Systemen steigt dabei mit der Frühzeitigkeit einer Unterstützung. Werden Warnungen zu früh ausgegeben, steigt die Gefahr, eine für den Fahrer als unnötig wahrgenommene Warnung auszugeben, das sog. Warndilemma. Produziert ein System zu viele als unnötig wahrgenommene Warnungen, verringert dies die Akzeptanz - bis hin zum vollständigen Deaktivieren des Systems durch den Fahrer.

Fahrermodellierung mit dem Ziel der Fahrerabsichtserkennung kann dabei unterstützen, Fahrerassistenzsysteme so an den Fahrer anzupassen, dass Warnungen nur in notwendigen Fällen ausgegeben werden. Dabei ist die Fahrerabsichtserkennung sehr komplex, da die Fahrzeugführung von inter- und intraindividuell verschiedenem Fahrerverhalten geprägt ist. Aufgrund dieser Komplexität liegt auch ein Forschungsbedarf zur Prädiktion von Fahrerverhalten vor, besonders im hochdynamischen und veränderlichen innerstädtischen Verkehr. In diesem Umfeld weisen Fahrmanöver mit hohem Querführungsanteil einen vermehrten Bedarf an Fahrerunterstützung auf. Dies ist Motivation für die Entwicklung eines Algorithmus zur Prädiktion eines innerstädtischen Fahrstreifenwechsels, welcher in dieser Arbeit realisiert wird.

Die Entwicklung folgt einem induktiven Ansatz und leitet Merkmale für eine Fahrmanöverprädiktion aus Daten ab. Ein sequentieller Prozess ist der geeignete Entwicklungsprozess dieser Anwendung, da die vollständigen Anforderungen in jedem Entwicklungsschritt verfügbar sind, die Ergebnisse unmittelbar mit den Anforderungen abgeglichen und direkte Aussagen zu einer möglichen Funktion abgeschätzt werden können. Entlang des Entwicklungsprozesses wurden die notwendigen Elemente theoretisch hergeleitet und entsprechende Designentscheidungen in Einklang mit den Anforderungen getroffen.

Zentrales Element dieser Arbeit ist ein Algorithmus zur Prädiktion von Fahrstreifenwechseln. Dieser Algorithmus basiert auf Verfahren des Maschinenslernens und benötigt für die Trainingsphase Daten. Diese Daten wurden mit dem Ziel der Repräsentation natürlichen Fahrerverhaltens in einer kontrollierten Feldstudie mit Probanden gewonnen. Aus den Daten wurden mit Hilfe eines quantitativen Bewertungsmaßstabs Merkmale extrahiert, um den Algorithmus mit einer geeigneten Menge an Eingangsgrößen trainieren zu können. Die Daten enthielten dabei Merkmale des Fahrerverhaltens auf der Basis von Fahrzeug- und Fahrerbeobachtungsdaten. Die am besten geeigneten Merkmale waren dabei Informationen zur Spurposition des Fahrzeuges und der horizontale Kopfwinkel des Fahrers.

Der Algorithmus basiert auf der Fuzzifizierung der Eingangsdaten und der Transformation der Fuzzy-Regeln in Fahrerverhaltenssequenzen. Mit Hilfe eines k-Nearest-Neighbor Verfahrens, unter Nutzung der Edit Distance als Distanzmetrik, werden in Echtzeit das Fahrerverhalten mit den gelernten Sequenzen verglichen sowie die Wahrscheinlichkeit und ein Zeithorizont für einen Fahrstreifenwechsel berechnet. Die Fahrerbeobachtungsdaten wurden durch das Hinzufügen eines Entscheidungs- und eines Regressionsbaumes mit dem Ergebnis der Auswertung der Verhaltenssequenzen fusioniert, um die Berechnung der Wahrscheinlichkeit bzw. zeitlichen Prädiktion zu verbessern. Die Leistungsfähigkeit des Algorithmus wurde mit Hilfe des Leave-one-out Kreuzvalidierungsverfahrens überprüft. Der Fokus der Bewertung des Algorithmus lag dabei, neben Richtig- und Falscherkennungsrate einer ROC-Analyse, auch auf der zeitlichen Vorhersage des Beginns eines Fahrstreifenwechsels.

Der entwickelte Algorithmus ermöglicht eine frühzeitige Prädiktion von Fahrstreifenwechseln im innerstädtischen Verkehr und bietet das Potential, aktive Fahrerassistenzsysteme durch die

---

Bereitstellung prädizierten Fahrerverhaltens zu verbessern, indem fahreradaptive Warnungen ausgegeben werden können.

Der Algorithmus wurde darüber hinaus in ein Demonstratorfahrzeug mit Hilfe prototypischer Hardware und einer Visualisierung integriert, um die Echtzeit- und Leistungsfähigkeit zu verifizieren und das Potential einer Fahrmanöverprädiktion zu demonstrieren.

Im Verlauf der Arbeit werden die Methodik und die Ergebnisse kritisch diskutiert. Die gewählte Methodik, der Entwicklungsprozess, der Bewertungsmaßstab und der entwickelte Algorithmus erfüllen die aufgestellten Kriterien und scheinen geeignet, Warnungen fahreradaptiv gestalten zu können. Zum Abschluss der Arbeit wird aufgezeigt, an welchen Stellen weiterer Forschungsbedarf bezüglich der Fahrmanöverprädiktion und der Verbesserung von Fahrerassistenzsystemen besteht.

---

## Inhaltsverzeichnis

---

Inhaltsverzeichnis	i
1..... Einleitung	1
1.1. Motivation	1
1.2. Zielsetzung	3
1.3. Aufbau der Arbeit	5
2..... Stand der Forschung und Technik	7
2.1. Fahrerverhaltensmodelle	9
2.2. Fahrerassistenzsysteme	12
2.3. Fahrmanöverprädiktion	16
2.4. Algorithmen zur Fahrmanöverprädiktion	21
2.5. Entwicklungsprozesse zur Algorithmenentwicklung	41
2.6. Zwischenfazit und Identifikation der Forschungslücke	45
3..... Methodik der Algorithmenentwicklung	47
3.1. Auswahl des Entwicklungsprozesses	47
3.2. Systemanforderungen	47
3.3. Softwareanforderungen	48
3.4. Analyse	50
3.5. Programmdesign	55
3.6. Programmieren und Umsetzen	59
3.7. Test	59
3.8. Einsatz	61
4..... Empirische Studie zur Datengewinnung	62
4.1. Probandenstudie	62
4.2. Merkmalsextraktion (Feature Engineering)	76
4.3. Bewertung der Prädiktoren zur Fahrerbeobachtung	79
4.4. Bewertungsmaßstab für Prädiktoren	85
5..... Algorithmenentwicklung	97
5.1. Algorithmus zur Fahrmanöverprädiktion	97
5.1.1. Fuzzifizierung der Eingangsgrößen	98
5.1.2. Lernen der Fahrerverhaltenssequenzen	101
5.1.3. Aufbau des Zustandsautomaten	104
5.1.4. Edit Distance Metrik	105
5.1.5. K-Nearest-Neighbor	108
5.1.6. Wahrscheinlichkeit und Zeithorizont	109
5.1.7. Designparameteroptimierung des Algorithmus	111
5.1.8. Bewertung und Validierung des Algorithmus	115
5.1.9. Erweiterung der Trainingsdaten	119
5.2. Integration von Fahrerbeobachtung	120
5.2.1. Stacking von Algorithmen	121

---

5.2.2.	Bewertung und Validierung des Algorithmus	127
5.3.	Implementierung in Demonstratorfahrzeug	128
6.....	Diskussion	135
6.1.	Diskussion der Methodik	135
6.2.	Diskussion der Performance des Algorithmus	141
6.3.	Diskussion der abgeleiteten Forschungsaufgabenstellung	145
7.....	Fazit und Ausblick	147
7.1.	Fazit	147
7.2.	Ausblick	147
7.2.1.	Mögliche Anwendungsfälle	148
7.2.2.	Weiterer Forschungsbedarf	149
1.....	Anhang	i
2.....	Literaturverzeichnis	v

---

## 1. Einleitung

---

In diesem Kapitel werden die Motivation des zu behandelnden Themas (Kapitel 1.1), die Zielsetzung dieser Dissertation (Kapitel 1.2) sowie der Aufbau dieser Arbeit (Kapitel 1.3) erläutert.

### 1.1. Motivation

Autofahren ist ein essentieller Bestandteil individueller Mobilität. Autofahren soll dabei nicht nur das Bedürfnis nach Mobilität befriedigen (Bengler et al. 2014), sondern auch Spaß machen. Allerdings erzeugt eine hohe individuelle Mobilität auch Nachteile, wie beispielsweise hohen Rohstoffverbrauch, Lärm oder Unfälle bis hin zur Todesfolge (Bengler et al. 2014).

Autofahren ist ein ebenso komplexer wie unfallträchtiger Vorgang. Im Jahr 2015 wurden durch die Polizei auf deutschen Straßen insgesamt 2.516.831 Verkehrsunfälle aufgenommen. Bei 305.659 Unfällen mit Personenschäden wurden 393.432 Personen leicht- und schwerverletzt und 3.459 Personen getötet (Statistisches Bundesamt 2016). Es gibt Bestrebungen, diese Zahl auf null zu reduzieren (Tingvall und Haworth 1999), jedoch ist dazu weiterhin wesentlicher Forschungsbedarf zur Erreichung dieses Zieles erforderlich (Benmimoun et al. 2012). Bei den Verkehrsunfällen mit Personenschaden war menschliches Fehlverhalten in 366.448 Fällen unfallursächlich (Statistisches Bundesamt 2016). Somit ist menschliches Fehlverhalten weiterhin die häufigste Unfallursache (Bengler et al. 2014).

Darüber hinaus gibt es eine unbekannte Anzahl von Beinahe-Unfällen, bei denen ein aufmerksamer Fahrer rechtzeitig durch angemessenes Verhalten die Entstehung eines Unfalls verhindern konnte. Nicht jeder Fahrer ist immer in der Lage, unsichere Situationen zu entschärfen, was zur Entwicklung und gesetzlich vorgeschriebenen Implementierung von Fahrerassistenzsystemen, wie Antiblockiersystem (ABS) und elektronischem Stabilitätsprogramm (ESP), geführt hat.

Auch die Entwicklung passiver Sicherheitssysteme, wie Gurt und Airbag, versprechen einen hohen Insassenschutz. Die Verletzungen beteiligter schwächerer Verkehrsteilnehmer, wie Radfahrer oder Fußgänger, können jedoch nicht entscheidend reduziert werden (Bengler et al. 2014). Eine Möglichkeit, diese Gefährdung für den Straßenverkehr durch menschliches Fehlverhalten zu reduzieren, ist die Entwicklung und Integration von aktiven Fahrerassistenzsystemen (FAS) in moderne Fahrzeuge (Winner et al. 2015). FAS sind Systeme, die den Fahrkomfort und die Fahrsicherheit erhöhen, indem sie den Fahrer bei der Fahrzeugführung unterstützen oder entlasten. Dadurch besitzen sie das Potential, nicht nur die Unfallschäden und Verletzungen zu mindern, sondern Unfälle zu verhüten.

Die Effektivität der FAS ist dabei bei Fahraufgaben mit hohem Fehlerpotential größer (Bartels et al. 2015). Fahrerassistenzsysteme können auf unterschiedliche Art auf den Fahrer einwirken. Sie können ihm Informationen bereitstellen, über akute Gefahren warnen, Handlungsempfehlungen zur Bewältigung einer Situation vorschlagen oder in begrenztem Umfang eine kritische Situation selbstständig entschärfen bzw. die Unfallschwere reduzieren.

Die Systeme mit warnendem oder handlungsempfehlendem Charakter besitzen dabei eine größere Wirksamkeit, wenn die Informationen möglichst frühzeitig dem Fahrer zur Verfügung gestellt werden. Somit wird dem Fahrer die Möglichkeit eröffnet, die Situation und Information zu verarbeiten und angemessen zu handeln. Wird eine Warnung jedoch zu früh ausgegeben, kann der Fahrer, welcher sich der vorliegenden Situation vollständig bewusst ist (Endsley 1988) und eine auftretende unsichere Situation selbstständig bewältigt hätte, sich durch diese subjektiv als unnötig empfundene Warnung gestört fühlen. In dieser Situation entsteht das sogenannte Warndilemma (Hoffmann und Gayko 2012). Durch diese, als unnötig empfundenen Warnungen, kann die Akzeptanz des Fahrers für das entsprechende FAS sinken (Fecher und Hoffmann 2015) und der Fahrer deaktiviert bei zu häufigen subjektiven Fehlfunktionen im schlimmsten Fall das gesamte System, wodurch es keine Wirkung mehr



---

entfalten kann (Bubb 2002). Dieser Zielkonflikt für die Parametrisierung von FAS muss adressiert werden, so dass FAS nur in absolut notwendigen Situationen selbstständig eingreifen und Warnungen auf ein notwendiges Minimum reduzieren, um eine möglichst hohe Effektivität und Fahrerunterstützung zu erreichen (Fecher und Hoffmann 2015). Dabei steht fest (Gründl 2002), dass FAS sorgfältig an den Fahrer angepasst sein müssen (Donges 2015). Weiterhin ist es von Vorteil, Fahrermerkmale, wie z.B. Fahrerzustand und insbesondere Fahrerabsicht, zu berücksichtigen und zur Parametrisierung der FAS zu verwenden (Blaschke et al. 2008). Insbesondere ist auf die Interaktion des Fahrers mit seinem Fahrzeug zu achten, aber auch auf die Interaktion des Fahrzeuges in seiner Umwelt (Donges 1982). Das größte Potential bietet bei der Unfallvermeidung eine Unterstützung des Fahrers auf der Führungsebene, hier wurden bisher nur wenige FAS entwickelt (Bubb 2002). Auf Navigationsebene durch Navigationsgeräte, und auf Stabilisierungsebene durch ABS oder ESP stehen hingegen eine ausreichende Menge an Fahrerunterstützungen zur Verfügung.

Ein Ansatz dazu ist, die Fahrzeugführung auf Führungsebene zu automatisieren, da die Fehleranfälligkeit dieser Systeme potentiell geringer ist, als die Fehlerrate menschlicher Fahrer. In den Bereichen von überschaubaren Verkehrssituationen mit einer hohen Homogenität, beispielsweise Stau oder freies Fahren auf der Autobahn, sind diese Systeme bereits im Serieneinsatz oder stehen unmittelbar davor. Diese Lösungen können den Menschen die monotonen Abschnitte des Autofahrens, wie das tägliche Pendeln zur Arbeit im Stau, abnehmen und somit bei genügender Produktreife, die Sicherheit und den Komfort erhöhen. Allerdings ist die Entwicklung automatisierter Systeme zur Fahrzeugführung in sehr heterogenem Verkehr, wie er beispielsweise im Stadtverkehr anzutreffen ist, noch lange nicht serienreif. Weiterhin ist das Autofahren ein Element, das zum Spaß beiträgt bzw. ausgeführt wird. So ist es auch vorstellbar, dass in Zukunft automatisierte Systeme zur Fahrzeugführung verfügbar sind, sie aber aus Gründen des Vergnügens abgeschaltet werden, um das Führen eines Fahrzeuges zu genießen. Auch hierbei sollte der Spaß nicht durch eine hohe Unfallgefahr getrübt werden. Somit ist parallel zur Entwicklung von Systemen zur automatisierten Fahrzeugführung eine Unterstützung des Fahrers bei der manuellen Fahrzeugführung weiterhin angebracht.

Auf der einen Seite ist die Entwicklung eines FAS für stark heterogene Verkehrssituationen hilfreich, andererseits wäre ein System zur Verbesserung vieler Assistenzsysteme durch Berücksichtigung des Fahrerverhaltens effizienter. Die Erkennung der Fahrerabsicht bietet dabei die Möglichkeit, durch Identifikation des aktuellen Fahrerverhaltens unter Berücksichtigung der Fahrsituation, ein gewisses Fahrerverhalten in einem kurzen Zeitraum zu prädictieren (Kretschmer et al. 2006). Wird einem FAS die Information über den Fahrer bereitgestellt, welches Fahrmanöver dieser als nächstes ausführt, kann das FAS mit Hilfe der Information die Notwendigkeit einer Unterstützung berücksichtigen und im Fall einer situationsgerechten, nicht notwendigen Unterstützung, diese unterdrücken (Manstetten et al. 2013) bzw. im Bedarfsfall der Unterstützung des Fahrers, diese dem Fahrer anbieten oder sogar verstärken (Blaschke et al. 2007). Gemäß Bengler et al. (2014) ist die Erkennung der Fahrerabsicht einer der wesentlichen Forschungsbereiche, dem ein Fokus in naher Zukunft gewidmet werden muss.

Dieses klingt bei oberflächlicher Betrachtung nach Gedankenlesen, aber mit Hilfe von Beobachtungen des Fahrerverhaltens ist es möglich auf zukünftiges Verhalten zu schließen, da die Fahrzeugführung ein stark gelernter Vorgang ist, welcher nach bestimmten Regeln abläuft. Diese Regeln werden zu Beginn des Autofahrens in der Fahrschule dem Fahranfänger beigebracht, beispielsweise die Nutzung des Schulterblicks vor dem Fahrstreifenwechsel zur Prüfung des Zielfahrstreifens auf andere Verkehrsteilnehmer, und während der selbstständigen Fahrzeugführung durch die erlebten Situationen verfeinert. Dadurch kommt es vor, dass, obwohl Fahrer eine nahezu identische Fahrausbildung erhalten haben, durch die unterschiedlichen erlebten Situationen bei der Fahrzeugführung, ihr Verhalten und die gezeigten Muster verschieden sind. Diese starken interindividuellen und weiterhin vorhandenen intraindividuellen Schwankungen zeigen, dass die Fahrzeugführung als äußerst komplex und darüber

---

hinaus als veränderlich anzusehen ist (Risse 1991). Bisherige Arbeiten haben gezeigt, dass Fahrmanöverprädiktion mit verschiedensten Ansätzen möglich ist (Bauer 2011; Berndt et al. 2008; Dambier 2010; Kobiela 2012; Kretschmer et al. 2006) und positive Auswirkungen auf FAS ermöglichen.

Die Informationen zur Fahrmanöverprädiktion können durch Nutzung von im Fahrzeug vorhandenen Daten des Controller-Area-Network (CAN) Bus gewonnen werden (Blaschke et al. 2007). CAN-Bus Daten stellen die technische Realisierung der Kommunikation der überwiegenden Anzahl von Steuergeräten in modernen Fahrzeugen untereinander dar. Sie beinhalten unter anderem Werte zur Bedientätigkeit des Fahrers, wie Lenkradwinkel oder Bremspedalposition, Informationen zum Fahrzeugzustand, wie laterale und longitudinale Beschleunigung, und Informationen zum Fahrzeugumfeld, wie Abstand zur Fahrstreifenmarkierung oder Abstand zum Vorderfahrzeug. Weitere Merkmale zur Fahrmanöverprädiktion können aus der Fahrerbeobachtung gewonnen werden. Fahrerbeobachtung bietet die Möglichkeit, Kopfbewegungen, Blickbewegungen oder Blickziele des Fahrers zu berechnen. Diese Sensorik ist jedoch zum heutigen Stand nicht vollumfänglich in serienmäßigen Fahrzeugen verfügbar.

Zur Verbesserung von FAS mit Hilfe von Fahrmanöverprädiktion ist ein echtzeitfähiger Algorithmus notwendig, der die erforderlichen Informationen über die vermutete Fahrerabsicht permanent dem FAS zur Verfügung stellt. Dieses ist bei einer Entwicklung zu berücksichtigen, da bei einer Implementierung nur begrenzt Speicherplatz und Rechenkapazität zur Verfügung stehen. Weiterhin sollte ein entsprechender Algorithmus stark an das menschliche Verhalten anpassbar sein, um dieses gut modellieren zu können und somit eine hohe Übereinstimmung zwischen Prädiktion und wirklichem Verhalten zu erreichen.

Bisher entwickelte Algorithmen und Verfahren stellen nicht das Optimum zur Prädiktion von Fahrerverhalten dar. Daher schlägt auch Murphy (2012) vor, viele verschiedene Modelle zu entwickeln und auf die große Bandbreite von Daten der realen Welt einzugehen, um verschiedene domänenspezifische Abwägungen zwischen Genauigkeit, Geschwindigkeit und Komplexität zu erreichen. Dieses motiviert die Entwicklung eines Algorithmus zur Fahrmanöverprädiktion.

## **1.2. Zielsetzung**

Zur Entwicklung eines Algorithmus zur Fahrmanöverprädiktion ist es notwendig, das menschliche Fahrerverhalten zu verstehen. Da eine vollumfängliche Analyse und Berücksichtigung aller Aspekte des Menschen für eine echtzeitfähige Anwendung mit aktueller Technik, aufgrund der enormen Komplexität des menschlichen Denkens, nicht möglich ist, sind Modelle mit reduziertem Umfang, spezialisiert auf einzelne Elemente, eine zielführende Herangehensweise. Diese reduzierten Modelle decken dabei den zu untersuchenden Bereich hinreichend ab und ermöglichen eine tiefergehende Analyse mit dem Fokus auf das Wesentliche. Die reduzierten Modelle sind daher Voraussetzung, um FAS an den Fahrer, mit dem Ziel der Verbesserung dieser Systeme, anzupassen.

Es gibt zwei denkbar mögliche Herangehensweisen zur Fahrermodellierung. Die Deduktion (top down Methoden) beschreibt dabei das Ableiten von Gesetzen und Theorien über Folgerungen, um auf Einzelbeobachtungen schließen zu können. Mit Hilfe der Induktion (bottom-up Methoden) lassen sich aus Beobachtungen Zahlen und Kennwerte generieren, um auf allgemeingültige Theorien zu schließen. Die Relation zueinander ist in Abbildung 1 dargestellt (Saint-Mont 2011).

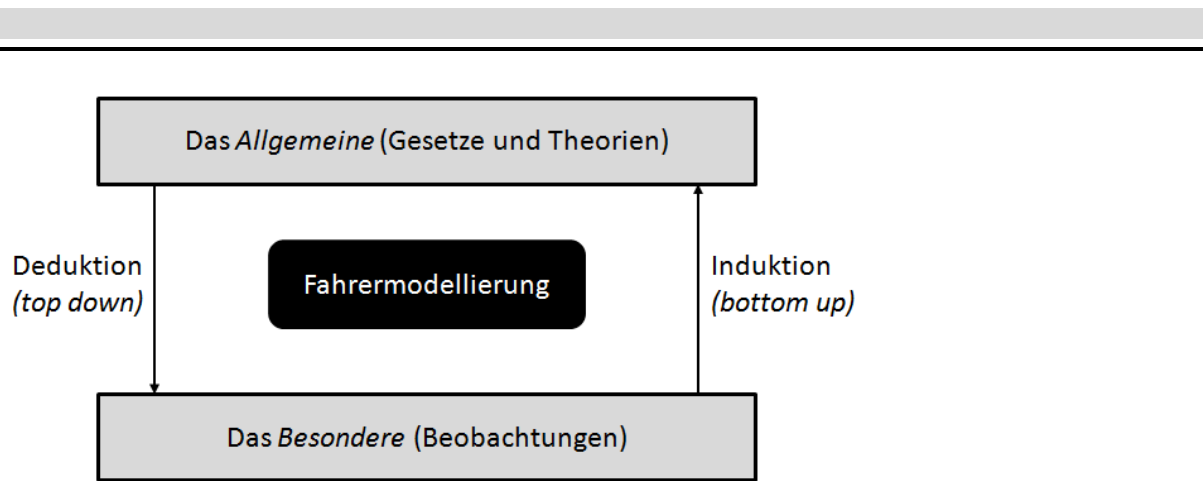


Abbildung 1: Schematische Darstellung von Deduktion und Induktion zur Fahrermodellierung

Top-down Methoden eignen sich, um aus der Theorie Vorgänge und Abläufe logisch abzuleiten und anhand von Beobachtungen der realen oder einer simulierten Welt zu überprüfen. Die Verwendung dieser Methodik zur allgemeinen Beschreibung von Fahrerverhalten ist in der Arbeit von Langer (2016) zu finden. Diese Methodik besitzt den Vorteil der Vollständigkeit und einer Erzielung allgemeingültiger Ergebnisse. Nachteilig wirken sich jedoch die hohe Komplexität und eine eventuell nicht erreichbare maschinenverarbeitbare Umsetzung der Erkenntnisse aus.

Bottom-up Methoden werden häufig in der Entwicklung von Fahrerassistenzsystemen eingesetzt (Rodemerk 2011). Dabei wird von der Teilsystemebene, wie z.B. Sensorik, zu Gesamtsystemen, wie einer komplexen Applikation, hin entwickelt (Meitinger 2008). Dieser Ansatz eignet sich insbesondere für Anwendungsfälle, bei denen die Zielszenarien bekannt sind und die Komplexität kontrollierbar ist (Meitinger 2008). Eine Allgemeingültigkeit kann bei diesem Verfahren nicht garantiert werden. Der Vorteil ist jedoch, dass bei der Entwicklung der Fokus auf einer Umsetzung für eine maschinelle Verarbeitung liegt und somit eine echtzeitfähige Anwendung in den meisten Fällen ermöglicht wird.

Bottom-up Methoden weisen durch die Verwendung und Ableitung von Merkmalen und Wissen aus Daten eine hohe Eignung zur Nutzung von Maschinenlernverfahren auf. Diese Verfahren können aus einem Datensatz mit Hilfe geeigneter Methoden Zusammenhänge und Gemeinsamkeiten finden und diese in ein Modell vereinen. Überwachte Maschinenlernverfahren benutzen dazu markierte Trainingsdaten, welchen mit Hilfe eines Postprocessing Metawissen hinzugefügt wurde, um dem Verfahren das Lernen einer Klassifikation zu ermöglichen. Ein System, welches Fahrmanöver erkennt, muss wissen, wann ein Fahrer einen Fahrstreifenwechsel durchführt oder ein anderes Manöver ausgeführt wird, um die Besonderheiten dieses Fahrmanövers extrahieren zu können. Unüberwachte Maschinenlernverfahren nutzen im Unterschied dazu explorative Suchmethoden, um bis dahin unbekannte Zusammenhänge zu finden und zu modellieren.

Zur Erstellung eines repräsentativen Fahrermodells ist eine umfangreiche Datenbasis notwendig. Diese Datenbasis sollte möglichst viele notwendigen Informationen und Zielszenarien enthalten, welche mit Hilfe von messbaren Merkmalen darstellbar sind.

Fahrversuche mit Probanden bieten eine gute Möglichkeit diese Daten zu erhalten, da die Probanden menschliches Verhalten bei der Fahrzeugführung repräsentieren und beinhalten. Es gibt verschiedene Versuchsumgebungen, um die notwendigen Daten zu sammeln (Bruder et al. 2007). Dabei eignen sich insbesondere Versuche im kontrollierten Feld, vor allem zur realistischen Darstellung von reproduzierbaren und auch kritischen Situationen (Bruder et al. 2007).

Nach der Modellierung des Fahrerverhaltens mit Hilfe empirischer Daten kann dieses Modell verwendet werden, um anhand von enthaltenen Merkmalen ein gewisses Fahrerverhalten zu präzisieren. Dieses ist

---

mit Hilfe geeigneter Algorithmen möglich. Die Leistungsfähigkeit hängt dabei wesentlich vom verwendeten Algorithmus und den zugrunde liegenden Daten ab.

Eine vollständige Modellierung des Fahrerverhaltens ist sehr umfangreich, daher konzentriert sich diese Arbeit auf die Prädiktion eines begrenzten Bereiches der Fahrzeugführung, um die Machbarkeit zu demonstrieren. Die Auswahl soll dabei den Fokus auf einen Bereich haben, der eine Fahrerunterstützung notwendig macht und darüber hinaus das Potential besitzt, viele Unfälle zu vermeiden.

Es gab im Jahr 2014 insgesamt 6031 Unfälle mit Personenschaden durch die Unfallursache des fehlerhaften Wechsels des Fahrstreifens beim Nebeneinanderfahren oder Nichtbeachtung des Reißverschlussverfahrens, von denen die Mehrzahl von insgesamt 3883 auf den innerstädtischen Verkehr fielen (Destatis 2015). Die Anzahl der Unfälle ohne Personenschaden liegt wahrscheinlich deutlich höher, wodurch das Fahrmanöver des Fahrstreifenwechsels zur Reduktion der Unfallzahlen weiterer Forschung bedarf und in dieser Arbeit fokussiert betrachtet wird. Die Häufung der Unfälle beim Fahrstreifenwechsel im innerstädtischen Verkehr zeigt die Notwendigkeit der Unterstützung des Fahrers und motiviert die gezielte Untersuchung des Fahrstreifenwechsels im innerstädtischen Verkehr.

Es existieren bereits FAS zur Fahrerunterstützung beim Fahrstreifenwechsel und auch die Prädiktion des Fahrerverhaltens beim Fahrstreifenwechsel wurde bereits als machbar aufgezeigt (Blaschke et al. 2008; Kretschmer et al. 2006; Schmidt et al. 2014). Allerdings blieb bei bisherigen Arbeiten Forschungsbedarf offen, weshalb sich diese Arbeit auf die Entwicklung eines Algorithmus zur Prädiktion von Fahrstreifenwechsel fokussiert.

### **1.3. Aufbau der Arbeit**

Im Kapitel 1 wurde der Bedarf der Forschung im Bereich der Fahrermodellierung aufgezeigt und die Notwendigkeit zur Entwicklung eines Algorithmus zur Fahrmanöverprädiktion motiviert.

Im Kapitel 2 wird der relevante Stand der Forschung aufgeführt und zusammengefasst. Dabei werden die relevanten Begriffe definiert und Fahrerverhalten beschrieben (Kapitel 2.1). Im nächsten Schritt werden vorhandene Fahrerassistenzsysteme vorgestellt (Kapitel 2.2) und die aktuellen Schwächen, welche diese Arbeit motivieren, aufgezeigt. Im Kapitel 2.3 werden die bisherigen Arbeiten zur Verbesserung von Fahrerassistenzsystemen mit Hilfe von Fahrmanöverprädiktion erläutert. Die notwendigen Algorithmen zur Fahrmanöverprädiktion werden im Kapitel 2.4 aufgeführt und analysiert. Da bisherige Algorithmen nicht das Optimum zur Verbesserung darstellen, werden Entwicklungsprozesse aufgeführt (Kapitel 2.5), mit denen neue Algorithmen entwickelt werden sollten, um die Verbesserung von Fahrerassistenzsystemen zu steigern. Abschließend wird im Kapitel 2.6 ein Zwischenfazit gezogen und die Forschungsfragen werden abgeleitet.

Im Kapitel 3 wird die verwendete Methodik der Arbeit vorgestellt. Dabei wird der passende Entwicklungsprozess ausgewählt und die notwendigen Schritte entlang des ausgewählten Entwicklungsprozesses werden aufgezeigt.

Kapitel 4 beinhaltet die empirische Studie zur Datengewinnung zur Algorithmenentwicklung, die Merkmalsextraktion (Kapitel 4.2) und ein Bewertungsmaßstab zur quantitativen Bewertung und Auswahl geeigneter Signale und Merkmale für die Algorithmenentwicklung (Kapitel 4.4). Kapitel 4.3 widmet sich speziell den Daten zur Fahrerbeobachtung, welche während der empirischen Studie gesammelt wurden und ebenfalls im Rahmen der Algorithmenentwicklung genutzt werden.

Im Kapitel 5 wird anhand der Entwicklungsmethodik ein Algorithmus zur Fahrmanöverprädiktion auf der Basis von Fuzzy Logik und Edit Distance mit Fahrzeugdaten entwickelt und validiert (Kapitel 5.1).

---

Weiterhin werden die Fahrerbeobachtungsdaten in den Algorithmus integriert und mit einer Variante ohne Fahrerbeobachtung verglichen, um das Potential zur Fahrmanöverprädiktion zu bewerten (Kapitel 5.2).

Im Kapitel 6 wird die verwendete Methodik kritisch hinterfragt. Im Speziellen werden dabei das Vorgehen, die verwendete Entwicklungsmethodik, die Probandenstudie und die Entwicklung des Algorithmus diskutiert (Kapitel 6.1). Darüber hinaus wird die Performance des entwickelten Algorithmus diskutiert, die Ergebnisse werden eingeordnet (Kapitel 6.2) und die Forschungsfragen aufgegriffen (Kapitel 6.3).

Im Kapitel 7 wird ein Fazit der Arbeit gezogen (Kapitel 7.1) und ein Ausblick auf mögliche zukünftige Forschungen und Anwendungsbereiche der erzielten Ergebnisse gegeben (Kapitel 7.2).

---

## 2. Stand der Forschung und Technik

---

In diesem Kapitel wird der aktuelle Stand der Forschung aufgeführt. Dabei werden wichtige zentrale Begriffe aufgeführt und definiert und Fahrerverhalten anhand von zutreffenden Fahrerverhaltensmodellen erläutert (Kapitel 2.1). Weiterhin werden Fahrerassistenzsysteme zur notwendigen Fahrerunterstützung aufgeführt und der Verbesserungsbedarf dargelegt (Kapitel 2.2). Anschließend werden Fahrermodellierung und Fahrmanöverprädiktion zur zielgerichteten Verbesserung von Fahrerassistenzsystemen beschrieben (Kapitel 2.3). Im Kapitel 2.4 werden bisherige Arbeiten zur Fahrmanöverprädiktion vorgestellt und mögliche Algorithmen aufgeführt. Aufbauend auf bisherige Arbeiten werden mit dem Ziel der Optimierung zur Verbesserung von Fahrerassistenzsystemen im Kapitel 2.5 Entwicklungsmethodiken aufgezeigt, welche zu einer zielgerichteten Entwicklung eines Algorithmus zur Fahrmanöverprädiktion beitragen können. Zum Schluss wird im Kapitel 2.6 ein Zwischenfazit gezogen und die wesentlichen Forschungsfragen abgeleitet.

### Definition zentraler Begriffe

In diesem Abschnitt werden die wesentlichen Begriffe dieser Arbeit definiert. Die jeweiligen Erläuterungen sind jeweils nur Abschnitte der vollständigen Theorien. Auf eine vollständige Erklärung aller angeschnittenen Themengebiete wurde verzichtet, um den Umfang der Arbeit zu begrenzen.

Die **Kraftfahrzeugführung** im Straßenverkehr, oder auch Fahrzeugführung genannt, beinhaltet, ein Fahrzeug mit Hilfe motorischer Steuerung der Bedieneinrichtung des Fahrzeuges, welches in diesem Fall eine zielgerichtete sensomotorische Tätigkeit darstellt (Luczak 1975), von einem Ausgangspunkt zu einem Bestimmungsort, entlang einer gewünschten Fahrtroute, zu bringen (Donges 2015). Der Fahrer nimmt bei der Fahrzeugführung Informationen aus der Umgebung auf, wertet diese aus, um die gewonnenen Informationen zielgerichtet umsetzen zu können. Die Umgebungseinflüsse, welche der Fahrer durch seine Sinnesorgane aufnimmt, bestimmen dabei sein Verhalten, um das Fahrzeug, seinen Wünschen entsprechend, zu führen. Das Fahrerverhalten wird dabei wesentlich von der Fahrsituation beeinflusst. Eine **Fahrsituation** ist durch die sequentiellen Interaktionen des Fahrers und seines Fahrzeuges mit der sich kontinuierlich ändernden Umgebung definiert und berücksichtigt dabei alle vorhandenen und relevanten Elemente, auch wenn sie durch den Fahrer nicht wahrnehmbar sind (Benda et al. 1983; Fastenmeier 1995; Rodemerk 2011). Eine Fahrsituation ist im Detail die Summe aus Art, Anzahl und Bewegung anderer Verkehrsteilnehmer, inklusive Relativgeschwindigkeit und Abstand zum eigenen Fahrzeug (Abendroth 2001).

Die Interaktion des Fahrers mit seinem Fahrzeug wird als **Fahraufgabe** beschrieben. Der Fahrer passt dabei die von ihm kontrollierbaren Größen, wie Fahrzeugposition im Fahrstreifen, auf die vorhandenen Führungsgrößen, wie z.B. Straßenverlauf, Position und Verhalten anderer Verkehrsteilnehmer oder weiteren Umgebungsbedingungen, an (Bubb, 2002). Er unterscheidet dabei zwischen der primären Fahraufgabe, welche als Hauptaufgabe das Halten des Fahrzeuges auf der Straße beinhaltet, der sekundären Fahraufgabe, welche u.a. die Betätigung des Fahrtrichtungsanzeigers (Blinker) oder des Scheibenwischers beinhaltet, und der tertiären Fahraufgabe, welche zur Unterhaltung oder zur Regulation des Klimas im Fahrzeug beitragen. Die Fahraufgabe lässt sich weiterhin, gemäß Bernotat (1970), in drei Ebenen unterteilen: **Stabilisierungsebene**, **Führungsebene** und **Navigationsebene**. Auf der Navigationsebene sind die Wahl der Fahrtroute sowie der Ablauf und die Schätzung des Zeitbedarfs verordnet. Auf der Führungsebene wählt der Fahrer entsprechend der Fahrsituation den gewünschten Kurs und die Geschwindigkeit und legt die auszuführenden Fahrmanöver zur Erfüllung der Entscheidung auf der Navigationsebene fest. Auf der Stabilisierungsebene korrigiert der Fahrer dann die Abweichung des aktuellen Fahrzeugzustandes von den auf der Führungsebene gewählten Sollgrößen.

---

Das Verhalten des Fahrers zur Fahrzeugführung wird durch den jeweiligen **Fahrerzustand** beeinflusst. Der Fahrerzustand untergliedert sich dabei gemäß Kopf (2005) in lang-, mittel- und kurzfristig veränderliche Faktoren. Die langfristig veränderlichen Faktoren, wie Fahrkönnen und -erfahrung, Persönlichkeit und Belastbarkeit, überdauern den Rahmen einer Fahrt und ändern sich nur über Monate bzw. Jahre. Mittelfristige Fahrerzustandsfaktoren sind während einer Fahrt veränderliche Faktoren, wie Tagesrhythmus, Müdigkeit oder aktuelle Fahrstrategie (Kopf 2005). Die kurzfristigen Elemente des Fahrerzustandes ändern sich innerhalb weniger Minuten oder Sekunden und beinhalten dabei Elemente wie gerichtete Aufmerksamkeit, Beanspruchung, Absicht, Vigilanz oder Situationsbewusstsein. Schlüsselfaktoren für verkehrssicheres Fahren stellen dabei nach Kopf (2005) hauptsächlich Aufmerksamkeit, Wachsamkeit, Beanspruchung, Situationsbewusstsein und Fahrerabsicht dar.

Ein relevanter Anteil am Fahrerzustand ist das **Situationsbewusstsein** (Situation Awareness) nach Endsley (1988), welches, entsprechend der Autorin, die Voraussetzung für eine Handlung ist. Dieses Element umfasst die Aufnahme von Informationen aus der direkten Umgebung, das Verstehen der Informationen im aktuellen Kontext und eine Antizipation zukünftiger Ereignisse. Das Situationsbewusstsein ist Voraussetzung für einen Fahrer zur sicheren Fahrzeugführung und aktiven Unfallvermeidung.

**Wachsamkeit** (Vigilanz) ist das Befinden des Fahrers, welche den Zustand der Ermüdung beinhaltet und die Fähigkeit des Fahrers, belastende Aufgaben erfolgreich absolvieren zu können, beschreibt Posner und Rafal (1987). Der Zustand der Müdigkeit, welcher sich durch eine ausreichende Exposition mit belastender Tätigkeit einstellt, reduziert die Fähigkeit des Fahrers, rechtzeitig auf sich ändernde Elemente des Umfelds zu reagieren. Sie kann durch Pausen oder Schlafen wieder reduziert werden.

**Aufmerksamkeit** gliedert sich in gerichtete und ungerichtete Aufmerksamkeit und beinhaltet nach Kopf (2005) die Bereitschaft, kleine und unvorhergesehene Änderungen der Umwelt zu entdecken, um auf diese reagieren zu können. Es existieren bereits einige Forschungsarbeiten zum Thema der Aufmerksamkeit (Höfer 2015; Trefflich 2010). Die Aufmerksamkeits- und Müdigkeitserkennung haben bereits die Implementierung in Serienfahrzeuge vollzogen (Winner et al. 2015).

Die **Belastung** der Fahrzeugführung erzeugt beim Fahrer, je nach Fertigkeiten und Eigenschaften, eine (unterschiedlich hohe) individuelle **Beanspruchung** (Belastungs- und Beanspruchungskonzept, Rohmert 1984). Diese Beanspruchung beeinflusst die Leistungsfähigkeit des Fahrers bei der Fahrzeugführung. Ist die Beanspruchung zu hoch oder zu niedrig, kann die Leistungsfähigkeit sinken und es können potentiell gefährliche Situationen entstehen.

Die **Fahrerabsicht**, oder auch Fahrerintention genannt, ist hauptsächlich der Führungs- und Navigationsebene (Donges 1982) zuzuordnen (Kopf 2005) und umfasst die in unmittelbarer Zukunft beabsichtigte und geplante Abfolge von Fahrmanövern (Kobiela 2012). **Intention** ist dabei das „Gerichtet sein auf ein Objekt, ein Ziel“ (Hecker und Stapf 1998; Kobiela 2012) und kann zur Vorhersage zukünftigen Verhaltens herangezogen werden (Ajzen 1991).

Bei der Fahrzeugführung ist ein **Fahrmanöver** eine Abfolge von Handlungen oder Aktionen, welches eine Fahrsituation in eine neue Situation überführt (Schneider 2009). Die Fahrmanöver finden auf dem taktischen Level der Fahrzeugführung, der Führungsebene, mit einem Zeithorizont von wenigen Sekunden statt (Kopf 2005). Nach Dambier (2010) ist das Fahrmanöver das aktuelle verhaltensbezogene Muster, welches der Fahrer für sein Fahrzeug bestimmt, und sollte als disjunkt betrachtet werden. Disjunkt bedeutet in diesem Fall, dass immer genau ein Fahrmanöver vom Fahrer ausgeführt wird und die Manöver sich nicht überschneiden.

---

## 2.1. Fahrerverhaltensmodelle

Es existieren vielfältige Ansätze und Methoden zur Modellierung des Fahrerverhaltens. Eine Übersicht ist in Levesque und Johrendt (2011) zu finden. Die Autoren stellen dar, dass bisher kein universelles Fahrermodell existiere. Das ist hauptsächlich durch die verschiedenen Anwendungsfelder der unterschiedlichen Modelle begründet. Ein Fahrermodell stellt dabei immer die Elemente des Menschen dar, welche für den jeweiligen Anwendungsfall notwendig sind. Sie reduzieren das Modell um die nicht benötigten Elemente, damit das Modell, gemäß dem Sparsamkeitsprinzip, beherrschbar ist. Grundsätzlich kann zwischen Informationsverarbeitungs- und Handlungsmodellen unterschieden werden (Langer 2016). Das Ziel der Fahrermodellierung ist das Verstehen des menschlichen Verhaltens und Gründe für ein gewisses Verhalten zu identifizieren. Sie ist notwendig, um Fahrerverhalten präzisieren zu können.

Das **Skill-Rule-Knowledge-Modell** (SRK) von Rasmussen (1983, 1985) beschreibt die hierarchisch angeordnete Handlungsregulation des Menschen und die verschiedenen kognitiven Belastungen, die davon ausgehen. Auf der fähigkeitsbasierten Ebene (skill level) werden dem Menschen dargebotene Reize erkannt und automatisierte Handlungen gemäß eines Reiz-Reaktions-Mechanismus ausgeführt. Dieser Mechanismus wurde durch unterschiedlich aufwändige Lernprozesse trainiert und läuft in einem selbstständigen Fluss ohne bewusste Kontrolle ab (Donges 2015). Auf der nächsthöheren Bewusstseinssebene, der regelbasierten Ebene (rule level), werden mit Hilfe von gelernten Regeln bekannte Situationen durch regelbasiertes Verhalten bewältigt. Dabei wird das gespeicherte Verhaltensmuster ausgewählt, welches in früheren Situationen die effektivste Handlungsweise beinhaltete (Donges 2015). Die dritte Ebene ist die wissensbasierte Ebene (knowledge level). Sie beinhaltet das höchste Bewusstsein zur Handlung in unbekannten Situationen, für die keine Regeln im Gedächtnis gespeichert sind, durch mentale Simulation verschiedener Handlungsalternativen und Bewertung zur Zielerreichung (Donges 2015). Der Mensch muss dabei die ihm unbekannte Situation und seine Umwelt bewusst analysieren und aktiv über eine Lösung der Aufgabe nachdenken, was die meisten kognitiven Ressourcen des Menschen in Anspruch nimmt.

Die Kombination von Fahrerverhalten gemäß Rasmussen (1983) unter Zuhilfenahme des Modells von Donges (1982) bezüglich des Fahrers, seines Fahrzeuges und der Umwelt (FFU), ist bei Donges (2015) zu finden (vgl. Abbildung 2). Dabei definiert er die Fahraufgabe als komplexe Überwachungs- und Regelungsaufgabe bei der aktiven Teilnahme als Führer eines Kraftfahrzeuges im Straßenverkehr.



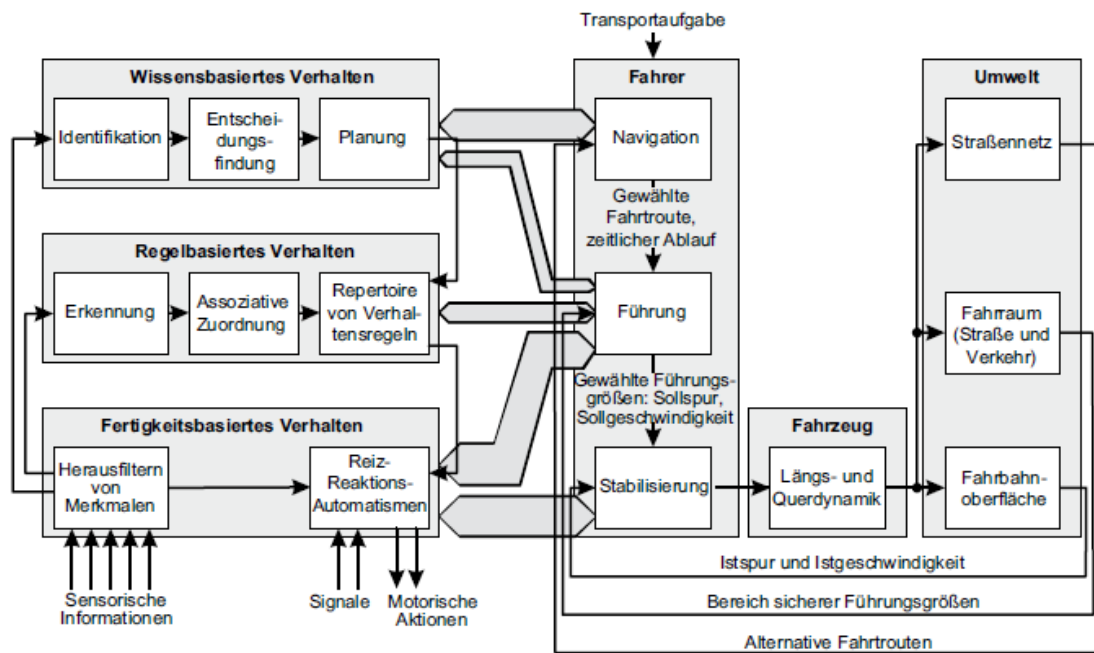


Abbildung 2: Kombination des Skill-Rule-Knowledge- und Fahrer-Fahrzeug-Umwelt-Modells (Donges 2015)

Die Verarbeitung von aktuellen Informationen, wie Verkehrsstörungen oder Einhaltung der Fahrtroute entlang markanter Merkmale, verlangen dem Fahrer den bewussten Prozess der Planung der Navigationsaufgabe ab und ist somit dem Prozess des wissensbasierten Verhaltens zuzuordnen (Donges 2015). Der dynamische Prozess der Fahrzeugführung findet auf den Ebenen der Führung und Stabilisierung statt und wurde bereits mehrfach in Form regelungstechnischer quantitativer Modelle abgebildet (Donges 2015). Die Ausprägung der Teilaufgabe Führung hängt von der Fahrerfahrung des jeweiligen Fahrers ab. Durch Erfahrungen werden aus wissensbasiertem Verhalten im Laufe der Zeit Regeln abgeleitet und dieselbe Aufgabe wird daraufhin auf der regelbasierten Ebene durch den Fahrer verarbeitet und umgesetzt (Donges 2015). Dieser Lernprozess geht so weit, dass sogar Tätigkeiten der Teilaufgabe Fahrzeugführung, z. B. die Regelung der Geschwindigkeit auf den gewünschten Sollwert, mit zunehmender Fahrerfahrung auf der fertigkeitsbasierten Ebene bearbeitet werden, welche nur durch das Auftreten unbekannter oder kritischer Bedingungen den Fahrer in die kognitiv anspruchsvolleren Verhaltensweisen zwingt (Donges 2015).

Die **Führungsebene** der Fahrzeugführung besitzt dabei, im Hinblick auf die Fahrzeugsicherheit, eine tragende Rolle (Donges 2015). Der Fahrer setzt seine antizipatorische Wahrnehmung und prädiktiven Fähigkeiten ein, um vorausschauende Handlungen einzuleiten und umzusetzen. Dabei steuert er, gemäß der Wahrnehmung der Umgebung durch seine Sinnesorgane und entsprechend seiner Wünsche, das Fahrzeug mit Hilfe von Lenkrad und Pedalen. Dieses beeinflusst die Fahrzeugdynamik, damit er durch Elemente der Führungsebene (Fahrmanöver) dem Ziel der Navigationsebene näher kommt. Dieser Prozess entspricht einem ständigen Prozess zur Regelung der Fahrzeugführung, in dem die Stellgrößen und Systemreaktionen messbar sind. Entsprechend der Ziele auf der Navigationsebene bildet der Fahrer seine Absicht, diese Ziele durch Umsetzung auf der Führungsebene, in diesem Fall Ausführung von Fahrmanövern, zu erreichen. Fahrerabsichten bzw. Intentionen ein Fahrmanöver durchzuführen, wurden auch von Diederichs (2016) untersucht. Er bezieht sich dabei auf das sogenannte **Rubikon-Modell** von Heckhausen und Gollwitzer (1987). Dieses ist in Abbildung 3 dargestellt.

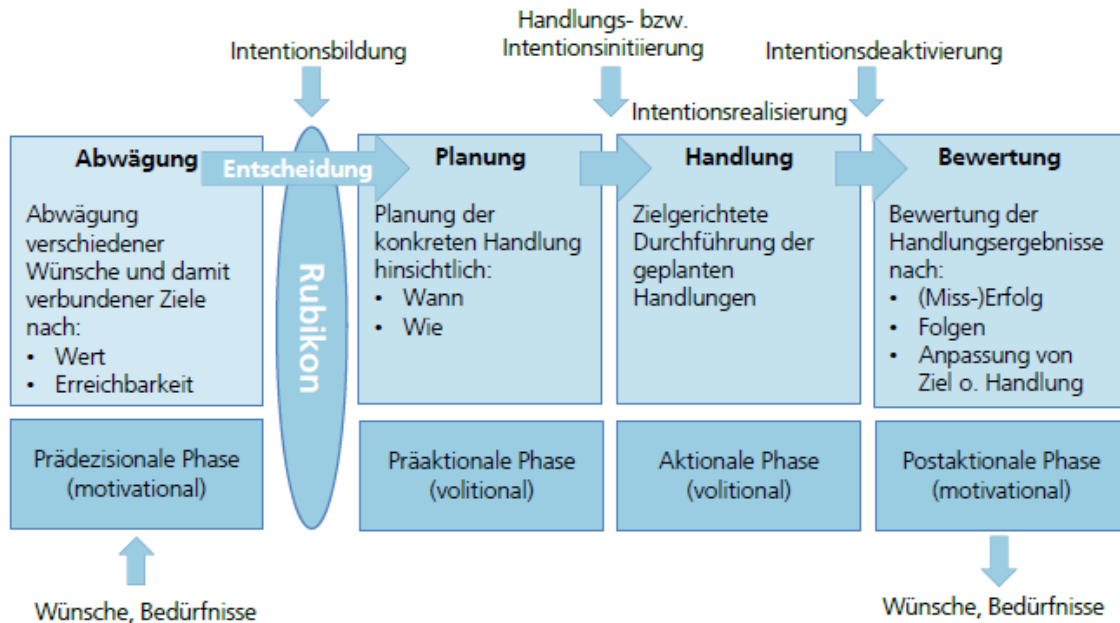


Abbildung 3: Rubikon Modell aus Diederichs (2016), angelehnt an Heckhausen und Gollwitzer (1987)

Das Modell beinhaltet kognitive Prozesse zur Entscheidungsfindung sowie Handlungsausführung. Es stellt ein motivationspsychologisches Modell dar, in dem ein Mensch seine Handlung entlang eines vierstufigen Prozesses anhand von Wünschen und Bedürfnissen abwägt, eine Intention bildet und sich dazu, durch den Schritt über den Rubikon, entscheidet und die Entscheidung dann mit Planung, Handlung und Bewertung umsetzt. Gemäß Diederichs (2016) lässt dabei die Phase der motivationalen Abwägungsphase keinen Hinweis auf ein geplantes Manöver zu, so dass Fahrerbeobachtung zur Aufmerksamkeitsrichtungs-schätzung nur die Wahrscheinlichkeit für die Auswahl eines bestimmten Fahrmanövers beeinflusst, jedoch kein bestimmendes Merkmal ist. Diese Merkmale können nach dem Modell erst nach der Entscheidung in der Planungsphase gefunden werden.

Eine große Herausforderung stellt dabei dar, dass menschliches Verhalten bei der Fahrzeugführung sehr komplex und darüber hinaus veränderlich ist (Risse 1991). So existieren zwischen verschiedenen Fahrern Unterschiede bezüglich der Fahrzeugführung (vgl. auch Doshi und Trivedi 2010), welche aus unterschiedlichen Fähig- und Fertigkeiten oder verschiedenen Zielen bei der Fahrzeugführung resultieren. Das **interindividuell** unterschiedliche Fahrerverhalten muss bei der Modellierung des Fahrerverhaltens berücksichtigt werden, um eine möglichst repräsentative Abbildung des Fahrerverhaltens aller Fahrer zu erhalten. Nicht nur interindividuell unterschiedliches Fahrerverhalten ist wesentlich, auch Unterschiede im Fahrerverhalten desselben Fahrers muss berücksichtigt werden. Die Forschungsinitiative INVENT (2005) hat herausgefunden, dass dieselben Fahrer, in mehrfacher Wiederholung vergleichbarer Situationen, ein unterschiedliches Blickmuster zeigten. Das bedeutet, dass derselbe Fahrer zu verschiedenen Zeitpunkten der Fahrt, durch eine gestiegene Müdigkeit, dieselbe Situation unterschiedlich erfasst und bewertet, was zu einem unterschiedlichen Verhalten führen kann. Dieses **intraindividuell** verschiedene Verhalten desselben Fahrers in vergleichbaren Situationen ist bei der Fahrermodellierung ebenfalls ein wesentlicher Einflussfaktor, welcher abgebildet werden muss. Nur durch eine Berücksichtigung von inter- und intraindividuellen Unterschieden im Fahrerverhalten bei der Modellierung kann mit Hilfe dieses Fahrermodells der Unterstützungsbedarf bestimmt werden. Die notwendige Fahrerunterstützung kann dann mit Hilfe von Fahrerassistenzsystemen (FAS) umgesetzt werden. Der nächste Abschnitt erläutert, welche Fahrerassistenzsysteme existieren und zeigt die Stärken und Schwächen sowie das Verbesserungspotential auf.

---

## 2.2. Fahrerassistenzsysteme

Es existieren Fahrerassistenzsysteme für jede der drei vorgestellten Ebenen der Fahraufgabe nach Donges (1982). Auf der Stabilisierungsebene wirken Assistenzsysteme, welche Handlungen schneller einleiten können als ein normal geschulter Fahrer, um das Fahrzeug in kritischen Situationen zu stabilisieren. Diese Systeme unterstützen durch das Verhindern des Blockierens der Räder beim Bremsen (Anti Blockier System, ABS) oder die Reduktion einer ungewollten Gierrate des Fahrzeuges (Elektronisches Stabilitätsprogramm, ESP). Auf der Führungsebene unterstützen Assistenzsysteme den Fahrer zum Beispiel bei einer Folgefahrt, indem Wunschgeschwindigkeit und ein Mindestabstand zu einem Vorderfahrzeug eingehalten und geregelt werden, oder die Spurhaltung wird durch aktive Lenkeingriffe unterstützt (Lane Keep Assist, LKA). Auf der Navigationsebene unterstützen und entlasten Systeme zur Routenberechnung, -anzeige und -führung den Fahrer bei der Erreichung des Fahrziels. Sie steigern die Sicherheit durch eine Reduktion der Belastung des Fahrers vor allem in unbekannter Fahrumgebung. Die Anzahl und Funktionen von Fahrerassistenzsystemen (FAS) werden gemäß Bengler et al. (2014) in naher Zukunft darüber hinaus noch wesentlich steigen.

Das ABS, entwickelt von der Firma Robert Bosch GmbH, war eines der ersten aktiven Assistenzsysteme, welches im Jahre 1978 in die Serienproduktion ging (Bengler et al. 2014). Nach Bengler et al. (2014) wurde im Jahr 1995 das ESP in den Serieneinsatz gebracht, welches von van Zanten und Kost (2012) als weiterer Meilenstein beschrieben wurde und in der Europäischen Union seit November 2014 gesetzlich vorgeschriebenes Ausstattungsmerkmal aller Neuwagen ist. Studien zeigen, dass Assistenzsysteme auf der Stabilisierungsebene die zweithöchste Effizienz für insassenfokussierte Assistenzsysteme darstellen und nur durch den Sicherheitsgurt übertroffen werden (Aga und Okada 2003; Bengler et al. 2014).

Die zweite Generation von FAS begann 1990 den Serieneinsatz und basierte zusätzlich zu den FAS der ersten Generation auf Sensoren, die das Fahrzeugumfeld erfassen konnten, um somit dem Fahrer zielgerichtete Informationen und Warnungen kontextbezogen präsentieren zu können und den Fahrkomfort zu steigern (Bengler et al. 2014). Die Entwicklung des adaptiven Abstandstempomats (Adaptive Cruise Control, ACC) (Winner 2012) war ein weiterer Fortschritt, da durch den Eingriff in die Beschleunigung und Bremse des Fahrzeuges unter Nutzung von Radar-Technologie, ein Assistenzsystem Zugriff auf die Steuerung des Fahrzeuges auf der Führungsebene erhielt und somit durch eine begrenzte Automatisierung der Längsführung, den Fahrkomfort und die Fahrsicherheit steigern konnte. Mittlerweile sind die ACC Systeme dahingehend fortgeschritten, dass unter Nutzung von Automatikgetrieben ein ACC mit Anhalte- und Anfahrfunktion im Serieneinsatz existiert. Weitere Assistenzsysteme auf Fahrzeugführungsebene können durch automatische Einleitung einer Gefahrenbremsung Kollisionen bei geringer Geschwindigkeit, unter Nutzung günstiger Frontal- und Umfeldsensorik, vermeiden. Diese Systeme werden seit 2010 von vielen Fahrzeugherstellern in Serienfahrzeugen angeboten.

Im Bereich der Unterstützung des Fahrers bei der Querführungsaufgabe wurden Systeme zur Spurverlassenswarnung (Lane Departure Warning, LDW) und zum aktiven Spurhalten (LKA) entwickelt und in Serienfahrzeuge integriert. Sie sind auf eine maschinelle Verarbeitung von Kameradaten einer frontal ausgerichteten, fahrzeugfesten Kamera angewiesen und stellen nach Ishida und Gayko (2004) dabei einen weiteren Meilenstein in der FAS Geschichte dar (Bengler et al. 2014). Bascunana (1995) hat für Fahrstreifenwechsel eine Assistenzfunktion erforscht, indem Zeitmaße theoretisch berechnet wurden, um zu entscheiden, ob ein auszuführender Fahrstreifenwechsel sicher ist oder der Fahrer Unterstützung benötigt. Dabei ist die Information zu vorhandenen Fahrzeugen im toten Winkel angebracht für abgelenkte oder unaufmerksame Fahrer, inkorporiert aber die Gefahr, eine als störend und ablenkend empfundene Information darzustellen. Die Warnung wird bei Bascunana (1995) ausgegeben, sobald der Fahrstreifenwechsel als unsicher eingestuft wird und der Fahrer den Blinker

---

aktiviert. Wenn der Fahrer die Absicht zum Fahrstreifenwechsel nicht mit Hilfe des Blinkers ankündigt, ist dieses System wirkungslos.

Auf der Navigationsebene haben sich Systeme etabliert, die den Fahrer bei der Routenfindung und dem Folgen der Route unterstützen. Sie nutzen Signale von geostationären Satellitensystemen, wie das Global Positioning System (GPS), um die Position eines Fahrzeuges auf der Erde zu lokalisieren. Rechnersysteme mit Kartendaten führen dann ein sogenanntes Mapmatching durch, um die räumlichen GPS-Koordinaten des Fahrzeuges in eine verwendbare Straßenkarte zu überführen und um eine Navigation vom aktuellen Standort zu einem gewünschten Ziel berechnen und anbieten zu können. Dabei erhöhen Navigationssysteme nicht nur den Fahrkomfort, sondern auch die Sicherheit, da Fahrer, nach Engels und Dellen (1989), im bekannten Umfeld seltener in Unfälle verwickelt sind als in unbekannter Umgebung (Bengler et al. 2014). Durch die Entlastung des Fahrers auf der Navigationsebene reduziert sich die Fahrerbelastung und die freigewordenen Ressourcen können für andere Fahraufgaben genutzt werden. Der nächste Schritt ist die Datenfusion von Sensordaten und -informationen, um die Stärken der einzelnen Systeme gewinnbringend zu vereinen. Somit können Längs- und Querführungsaufgaben vom Fahrzeug, zuerst in niedrigen Geschwindigkeitsbereichen, übernommen werden (Bengler et al. 2014).

Weitere Assistenzsysteme, welche durch die stetig steigende Leistungsfähigkeit von Sensorik und Rechnern zur Datenverarbeitung potentiell als nächstes in Serienfahrzeuge integriert werden, sind u.a. Systeme zur automatischen Kollisionsvermeidung durch Ausweichmanöver (Dang et al. 2012), Systeme zur Kollisionsvermeidung mit Fußgängern (Enzweiler und Gavrila 2009), Kreuzungsassistenzsysteme (Hopstock und Klanner 2007). Der Trend setzt sich fort bis hin zu Systemen, welche einen Sicherheitsgewinn unter Nutzung von vernetzten Fahrzeugen und Infrastruktur ermöglichen, mit der dahingehend erheblich höheren Reichweite der Informationsgewinnung im Vergleich zu klassischen Fahrzeugsensoren (Bengler et al. 2014).

Aktuell ist die Forschung im Bereich des automatisierten Fahrens sehr stark hinsichtlich Assistenzsystemen, welche (zu einem gewissen Teil) die Fahrzeugführung vom Fahrer übernehmen und Assistenzsysteme zum automatisierten Fahren in kontrollierten Situationen, wie der Stauassistent. Jedoch ist der Anwendungsfall für das Fahren in urbanen Regionen durch das diverse Umfeld deutlich komplexer, so dass aktuelle Technologien den Umgang in diesen Situationen nicht beherrschen (Bengler et al. 2014). Daher ist eine Assistenz von Fahrern bei der manuellen Fahrzeugführung im urbanen Verkehr weiterhin angebracht und eine Forschung in diesem Bereich essentiell, um Unfallzahlen zu reduzieren (Manstetten et al. 2013). Bis eine vollständige Automatisierung des Fahrens auch in diesen Bereichen erreicht wird, ist Fahrerassistenz durch FAS notwendig und angebracht (Bengler et al. 2014).

Die nächste Verbesserung von Fahrerassistenzsystemen besteht darin, den Fahrer zu beobachten und alle Aktionen seinem Zustand und Verhalten anzupassen. Dieses ist u.a. durch Erkennung der Müdigkeit möglich. Es existieren Systeme, die im Fall einer detektierten Müdigkeit den Fahrer darauf hinweisen eine Pause einzulegen, um wieder einen Zustand geringerer Müdigkeit zu erreichen und die Fahrsicherheit zu erhöhen. Eine weitere Möglichkeit ist, Fahrerwarnungen an den, durch Fahrerbeobachtungskameras festgestellten, Aufmerksamkeitsbereich des Fahrers anzupassen, um die Akzeptanz und den Wirkungsbereich zu erhöhen (Trivedi et al. 2007). Zwerschke (2006) beschreibt, dass obwohl die Akzeptanz für FAS steigt, die Funktionsweise oft nur schlecht durch den Nutzer verstanden wird. Dieses führt gemäß Krüger (2008) zu dem Problem, dass die wenigsten Kunden FAS in Fahrzeugen der Kompaktklasse bestellen und die meisten FAS auch nicht durch nachfolgende Nutzer auf- oder nachgerüstet werden können. Dadurch kann eine wichtige Zielgruppe, junge und unerfahrene Fahrer, für FAS nicht erreicht werden (Bengler et al. 2014). Das bedeutet, dass FAS einerseits nicht nur in teuren Fahrzeugen zu hohen Preisen, sondern auch zu einem vom Nutzer als angemessen beurteilten Preis in günstigeren Fahrzeugen angeboten werden müssen. Durch eine hohe Verbreitung von FAS in

---

günstigen Fahrzeugen, steigt die Anzahl von Fahrzeugen mit sicherheitssteigernden FAS auf den Straßen. Dadurch eröffnet sich die Chance, allen Teilnehmern im Straßenverkehr neue Sicherheitstechnologien zur Steigerung der Verkehrssicherheit anzubieten. Die Integration von neuen FAS werden unter anderem durch die neuen European New Car Assessment Programme (Euro NCAP), Bewertungsmethode (Euro NCAP 2016), vorangetrieben, wobei die maximale Punktzahl für ein Fahrzeug durch den Hersteller nur durch die Integration aktiver FAS zu erreichen ist. Dadurch erhalten Fahrzeughersteller Anreize, solche Systeme auch in weniger rentablen Marktsegmenten anzubieten, um weiterhin eine hohe Bewertung ihrer Fahrzeuge zu erhalten. Überdies ist eine Steigerung der Kundenzufriedenheit notwendig, damit zukünftige Systeme häufiger verkauft werden und mehr Fahrzeuge mit diesen Systemen ausgestattet sind. Eine hohe Kundenzufriedenheit kann durch bessere Funktionalität und nutzerfokussierter Auslegung der FAS erreicht werden.

Die Entwicklung von FAS ist jedoch noch nicht standardmäßig nutzerfokussiert, was gem. Maurer (2012) zu einer geringen Nutzerakzeptanz beiträgt (Bengler et al. 2014). Ein wesentlicher Punkt bei der zukünftigen Entwicklung von FAS ist, den Nutzer in die Entwicklung einzubeziehen, zum Beispiel durch eine Anpassung der funktionalen Parameter und der Bedienschnittstelle an die Bedürfnisse des Bedieners (Bengler et al. 2014). Der Fokus auf transparente Systeme mit guter Nutzbarkeit und gemäß Krüger (2008) mit Bedienschnittstellen hoher hedonischer Qualität sollte zu einer höheren Akzeptanz und dadurch zu einer höheren Marktdurchdringung führen. In Bezug auf die voranschreitende Entwicklung des autonomen Fahrens ist es wichtig, die Aufgabenverteilung zwischen Fahrzeug und Fahrer intuitiv und zuverlässig zu gestalten (Bengler et al. 2014).

Idealerweise können FAS an das Verhalten des Fahrers angepasst werden, wenn diesem System Informationen über zukünftiges Verhalten vorliegen. Im Bereich der Navigation kann dem Fahrer rechtzeitig vor einer Kreuzung angesagt werden, dass ein Abbiegemanöver auszuführen ist und der Fahrer genügend Zeit hat, sich auf das Manöver vorzubereiten, indem er in den richtigen Fahrstreifen wechselt. Wünschenswert wäre es darüber hinaus, den Fahrer bei der Ausführung einzelner Fahrmanöver zu unterstützen. Eine Verbesserung eines Totwinkelwarners, welcher nur zum Zeitpunkt eines anstehenden Fahrstreifenwechsels warnt, wäre eine zielgerichtete Verbesserung dieses Assistenzsystems. Mit Hilfe von Fahrerabsichtserkennung ist solch eine Prädiktion von Fahrmanövern für kurze Zeithorizonte möglich.

**Fahrerabsichtserkennung** befindet sich derzeit im Forschungsstadium, besitzt aber hohes Potential zur adaptiven Gestaltung von Fahrerwarnungen (Manstetten et al. 2013). Auch Bengler et al. (2014) definieren die Fahrerintentionserkennung als einen wesentlichen Forschungsbereich, dem ein zukünftiger Fokus gewidmet werden muss. Ein Fahrer kann viele verschiedene Absichten vereinen. Beispielsweise kann er die Absicht haben, das Ziel der Fahrt auf möglichst ökonomischen Weg zu erreichen oder bei einer Fahrt ein Hörbuch hören zu wollen. Diese Absichten erstrecken sich auf die Navigationsebene. Weitere Absichten können darüber hinaus sein, ein Fahrzeug überholen zu wollen, um das Ziel schneller zu erreichen. Das direkte Planen und Ausführen eines Fahrstreifenwechsels, um ein vorausfahrendes Fahrzeug zu überholen, ist der Manöverebene zuzuordnen.

Da sicherheitskritische Situationen hauptsächlich auf der Manöver- und nicht auf der Navigationsebene (Rodemerk 2011) entstehen, sind für Fahrerassistenzsysteme vor allem diese Ebenen von Relevanz. Die Stabilisierungsebene ist durch die Implementierung von ABS und ESP aktuell als weniger kritisch anzusehen. Die Kenntnis über das vom Fahrer als nächstes beabsichtigte Fahrmanöver kann dabei die Wirkung von Fahrerassistenzsystemen verbessern (Diederichs 2016).

Fahrerassistenzsysteme können in drei unterschiedlichen Arten auf den Fahrer einwirken, welche sich durch die Kritikalität der Situation unterscheidet. In der geringsten Stufe gibt ein Fahrerassistenzsystem dem Fahrer eine **Information**. Diese Art der Rückmeldung ist unkritisch und soll den Fahrer auf eine

---

entfernte Handlung hinweisen, wie z.B. die Information eines Navigationsgerätes, welches ca. 1000 m vor einer Kreuzung den Fahrer darüber informiert, dass er an dieser Kreuzung links abbiegen muss. Die nächste Stufe der Rückmeldung ist die **Warnung**. Eine Warnung soll den Fahrer auf eine unmittelbar folgende gefährliche Situation hinweisen und ihn zu einer Handlung veranlassen. Beispielsweise wie bei einem Totwinkelassistent, der ein Fahrzeug im toten Winkel mittels Ultraschall oder Kurzstreckenradar erkennt und bei einem anstehenden Fahrstreifenwechsel, welcher durch die Aktivierung des Blinkers detektiert wird, auf die bevorstehende Kollision durch einen Warnton hinweist. Der Fahrer nimmt diese Warnung wahr und entscheidet, welche Handlungsalternative zu wählen ist, um eine Kollision zu vermeiden. In nochmals kritischeren Situationen oder in Situationen, in denen der Fahrer nicht mehr rechtzeitig reagieren kann, unterstützen **eingreifende Fahrerassistenzsysteme** den Fahrer, um direkt bevorstehende Kollisionen zu vermeiden oder den Schaden zu minimieren. Ein Beispiel für solche Systeme sind automatische Notbremsysteme. Diese erkennen mit Hilfe von Kamera oder Radarsensoren, ob der Abstand und die Geschwindigkeitsdifferenz zu einem vorausfahrenden Fahrzeug kritische Werte erreichen. Falls die Zeit bis zu einer Kollision durch eine Fahrerwarnung und eine davon motivierte Fahrerreaktion die Kollision nicht verhindern kann, greift das System selbstständig, zur Kollisionsvermeidung, in die Fahrdynamik des Fahrzeuges ein.

Informierende Fahrerassistenzsysteme tragen nicht unmittelbar zur Verringerung von Unfällen bei. Eingreifende Assistenzsysteme warten oftmals bis zum letzten physikalisch möglichen Moment, um eine Kollision zu vermeiden und greifen somit stark in den Komfort der Fahrzeuginsassen ein. Eine Unfallvermeidung unter möglichst hoher Aufrechterhaltung von Komfort bietet eine möglichst frühzeitige Warnung. Eine Warnung wirkt dabei hauptsächlich auf den visuellen, auditiven oder haptischen Sinneskanal, in einer Intensität oberhalb der Reizschwelle und unterhalb einer Schmerzschwelle (Hoffmann und Gayko 2012). Die Reize werden durch den Fahrer aufgenommen, verarbeitet und er trifft daraufhin, entsprechend den von ihm bestimmten Handlungsoptionen, eine Entscheidung zu einer angemessenen Reaktion. Eine Warnung sollte dabei so spät wie möglich, jedoch so früh wie nötig ausgegeben werden, um eine maximale Zuverlässigkeit zu erreichen (Naujoks et al. 2012). Reale Fahrerassistenzsysteme sind, aufgrund von Sensorungenauigkeiten oder ungenauer Vorhersage der Entwicklung der vorliegenden Verkehrssituation, nicht perfekt, was in einzelnen Situationen zu Fehlwarnungen führen kann.

**Fehlwarnungen** und subjektiv als falsch beurteilte Warnungen, sowie subjektiv unberechtigte automatische Übernahmen der Fahrzeugkontrolle durch eingreifende FAS, werden vom Fahrer als besonders störend empfunden, wodurch die Akzeptanz für diese Systeme reduziert wird (Diederichs 2016; Endsley 1995; Hoffmann und Gayko 2012). Im schlimmsten Fall treten entgegenwirkende Handlungen zwischen Fahrer und Assistenzsystem auf, welche die Fahrsicherheit negativ beeinflussen (Diederichs 2016). Ein System zum automatischen Ausweichen in Notsituationen kann eine geplante unfallvermeidende Trajektorie nur dann vollständig erfolgreich fahren, wenn der Fahrer das System nicht durch einen Bremsengriff übersteuert. Eine Möglichkeit Fehlwarnungen zu reduzieren, ist die Berücksichtigung des aktuellen Fahrerzustandes in die Berechnung, ob und wann eine Warnung notwendig ist.

Ein fahreradaptiver **Warnzeitpunkt** ergibt sich durch Berücksichtigung des Fahrerzustandes, insbesondere durch Ablenkung und Fahrerintention. Einem aufmerksamen Fahrer mit einem angemessenen Situationsbewusstsein kann eine Kollisionswarnung zu einem späteren Zeitpunkt dargestellt werden, um die gleiche Wirksamkeit zu erreichen, als einem abgelenkten Fahrer (Höfer 2015). Höfer (2015) zeigt, dass abgelenkte Fahrer insbesondere von frühen Warnzeitpunkten profitieren können und darüber hinaus eine höhere Toleranz für Fehlwarnungen zeigen. Donges (2015) beschreibt, dass Warnsysteme eine Antizipationszeit von drei Sekunden möglichst überschreiten sollten, falls vom Fahrer eine kognitive Verarbeitung der Information notwendig ist. Wakasugi (2005) sagt, dass

---

Warnungen vor einem Fahrstreifenwechsel dem Fahrer spätestens zwei Sekunden vor der Entscheidung zu dem Fahrmanöver dargestellt werden sollten. Auch Naujoks et al. (2012) kommen zu einem ähnlichen Ergebnis, dass Fahrer Informationen zwischen zwei und drei Sekunden vor dem letztmöglichen Warnzeitpunkt präferieren. Die Wirksamkeit einer Warnung steigt, je frühzeitiger diese dem Fahrer dargestellt wird (Hoffmann und Gayko 2012). Durch eine frühestmögliche Darbietung von Warnungen entsteht jedoch ein weiteres Problem. Je früher eine Warnung ausgegeben wird, desto höher ist die Gefahr, dass diese Warnung eine Fehlwarnung sein kann (Hoffmann und Gayko 2012). Eine frühzeitige Warnung könnte in einer Verkehrssituation ausgegeben werden, obwohl sich diese kritische Situation bis zu dem Zeitpunkt der durch den Fahrer notwendigen Handlung, selbstständig auflöst, oder ein Fahrer sich der aktuellen Verkehrssituation vollständig bewusst ist und bereits ein Fahrmanöver zur Entschärfung der kritischen Situation plant, zum Beispiel durch einen Fahrstreifenwechsel. In diesen Fällen ist die Warnung zum Zeitpunkt der Darstellung aus Sicht des FAS korrekt, der Fahrer kann diese Warnung jedoch als unnötige Warnung oder als Fehlwarnung interpretieren. Treten diese Fehlwarnungen häufiger auf, sinkt das Vertrauen in das FAS und die Fahrer könnten dieses System, aufgrund der störend empfundenen Warnungen, abschalten. Dadurch kann das System in notwendigen Situationen, in denen der Fahrer eine Warnung benötigt, diese nicht darstellen und es kann eine kritische Situation entstehen oder ein Unfall passieren. Die gegensätzliche Anforderung an warnende FAS möglichst frühzeitig, jedoch mit geringer Fehlauflösungsrate, zu warnen, ist das sogenannte Warndilemma (Hoffmann und Gayko 2012).

Ein **Warndilemma** entsteht, wenn die Fahrerabsicht, das Zielobjektverhalten oder der Aufmerksamkeitszustand des Fahrers unbekannt sind (Höfer 2015). Insbesondere im Stadtverkehr können häufiger Situationen entstehen, bei denen Fahrer, zugunsten des fließenden Verkehrs, geringe Abstände in longitudinaler (zu Vorfahrern) und lateraler Richtung (zu Fahrradfahrern) bewusst in Kauf nehmen (Diederichs 2016). Die Darbietung einer Warnung in diesen Situationen kann als störend empfunden werden, da sie nicht der Handlungsintention und Situationswahrnehmung des Fahrers entspricht (Diederichs 2016).

Gemäß Donges (2015) ist die Unterstützung des Fahrers auf der Führungsebene hochrelevant und darüber hinaus die vielversprechendste Unterstützungsebene für zukünftige FAS. Dieses geht auf die quantitativen Ergebnisse der Studien zur Fahrermodellierung, verknüpft mit dem Drei-Ebenen-Modell (Donges 1982), zurück. Dem Fahrer sollte bei einer Warnung eine Antizipationszeit von mindestens zwei Sekunden eingeräumt werden, da Reaktionsanforderungen, welche deutlich unterhalb dieser Schwelle liegen, nur durch automatische Assistenzsysteme bewältigt werden können (Donges 2015). Daher sollte ein Fokus der Forschung, gemäß Bengler et al. (2014), auf der wahrscheinlichkeitsbasierten Erkennung und Modellierung zukünftigen Fahrerverhaltens liegen, um die Leistungsfähigkeit von Assistenzsystemen zu steigern (Liebner et al. 2013).

Der Fokus dieser Arbeit richtet sich folgerichtig auf die Forschung zur Verbesserung von FAS auf der Führungsebene mit dem Ziel, Warnungen möglichst zeitgerecht, unter Reduktion eines Warndilemmas, ausgeben zu können. Zur Realisierung dieser Anforderung ist eine Prädiktion des Fahrerverhaltens sinnvoll, um in Situationen, in denen der Fahrer Unterstützung durch ein FAS benötigt, Warnungen möglichst früh präsentieren zu können, ohne ein Warndilemma mit einer hohen Anzahl unnötiger Warnungen entstehen zu lassen.

### 2.3. Fahrmanöverprädiktion

Die **Fahrmanöverprädiktion** ist ein Element zur Verbesserung von FAS. Fahrmanöverprädiktion leitet aus spezifischen Merkmalen, wie die Aktivierung des Blinkers vor einem Fahrstreifenwechsel, Informationen und Hinweise ab, um ein anstehendes Fahrmanöver präzisieren zu können. Mit Hilfe der

Prädiktion zukünftigen Fahrerverhaltens kann der Unterstützungsbedarf eines Fahrers in der anstehenden Verkehrssituation abgeschätzt werden, um ihm die notwendige Art und Menge an Assistenz durch FAS anbieten zu können.

Zur Prädiktion von Fahrmanövern ist es wichtig zu verstehen, was ein Fahrmanöver ist und welche Fahrmanöver existieren. Ein **Fahrmanöver** ist eine Folge von Aktionen, welche die aktuelle vorliegende Fahrsituation in eine neue überführt (Schneider 2009). Mehrere Autoren haben **Fahrmanöverkataloge** aufgestellt, die alle wesentlichen Fahrmanöver enthalten sollen. Nagel und Enkelmann (1991) summierten 17 verschiedene Fahrmanöver zu einem Fahrmanöverkatalog. Dieser Katalog wurde durch Tölle (1996) zu einem Katalog mit neun Fahrmanövern zusammengefasst. Der Fahrmanöverkatalog von Dambier (2010) zeichnet sich durch die zuvor erwähnte disjunkte Eigenschaft aus, deckt insgesamt 12 Fahrmanöver ab und enthält, im Unterschied zu den vorher genannten Katalogen, auch ein Element mit besonderen Fahrmanövern, welche unter anderem Handlungen zur Unfallvermeidung beinhalten. Daher wird in der weiteren Arbeit der Fahrmanöverkatalog von Dambier (2010) verwendet.

Tabelle 1: Fahrmanöverkatalog nach Dambier (2010)

1	Stillstand
2	Fahrstreifenwechsel
3	Abbiegen
4	Anfahren
5	Folgen
6	Anhalten
7	Annähern
8	Passieren
9	Überholen
10	Langsames navigieren (zur Korrektur der Orientierung)
11	Parkmanöver
12	Besondere Fahrmanöver (z.B. zur Unfallvermeidung)

Unterschiedliche Fahrmanöver besitzen unterschiedliche Anforderungen an den Fahrer. Im Fahrmanöver Stillstand sind die Anforderungen an den Fahrer deutlich geringer, als die Anforderungen während des Fahrmanövers Überholen. Somit besteht auch verschiedener Unterstützungsbedarf des Fahrers bei unterschiedlichen Fahrmanövern. Es existieren Fahrmanöver, bei denen die Herausforderungen hauptsächlich in der Kontrolle longitudinaler Werte bestehen, wie das Folgen eines anderen Fahrzeuges, und Fahrmanöver mit Kontrolle longitudinaler und lateraler Bewegungen des Fahrzeuges, wie Fahrstreifenwechsel. Letztere Fahrmanöver stellen dabei eine höhere Anforderung an den Fahrer und besitzen somit einen höheren Bedarf zur Unterstützung des Fahrers. Als Beispiel dieser Manöver soll im Weiteren der **Fahrstreifenwechsel** (FSW) tiefergehend betrachtet werden, da dieser sowohl Längs- als auch Querführungselemente der Fahrzeugführung beinhaltet und die Aufmerksamkeit des Fahrers nicht nur auf den eigenen Fahrstreifen, sondern auch auf den Zielfahrstreifen gerichtet sein muss.

Nach Wierwille (1984) läuft ein natürlicher **Fahrstreifenwechsel** wie folgt ab: Der Fahrer signalisiert seinen Fahrstreifenwechsel durch Aktivierung des Blinkers und gibt daraufhin eine Lenkeingabe vor, wodurch eine Änderung des Winkels des Fahrzeuges zur Fahrstreifenmarkierung entsteht und worauf sich ein lateraler Versatz aufbaut. Sobald die gewünschte laterale Position im Zielfahrstreifen erreicht ist, reduziert der Fahrer durch entgegengesetzt gerichtete Lenkeingabe den Winkel wieder, um eine laterale Bewegung des Fahrzeuges zu stoppen. Dabei kann das Fahrzeug eine beliebige longitudinale Geschwindigkeit in Verbindung mit diversen möglichen Längsbeschleunigungen aufweisen. Zum



---

Abschluss deaktiviert er den Blinker und setzt das Folgen des Fahrstreifens fort. Ein Fahrstreifenwechsel dauert dabei zwischen 3s und 7s (Olsen 2003).

Die Ausführung eines idealen Fahrstreifenwechsels ist in McKnight und Adams (1970) dargestellt:

- Desire to change lane
- Check if lane change legal
- Check if lane change is okay:
  - o Check Mirrors for rear approaching vehicles
  - o Look to Blind spot for vehicle in new lane
  - o Scan ahead for lead vehicle in new lane
  - o Look to far adjacent lane for vehicles entering new lane
  - o Identify roadway limitations to lane change
- Signal intent to change lane
- Apply steering input
  - o Correct lateral position
- Apply opposite steering input
  - o Heading deviation removed
- Turn off turn signal
- Resume to lane keeping

FSW können nach Chovan (1994) durch die Richtung, FSW von rechts nach links oder von links nach rechts, unterschieden werden. Darüber hinaus ist eine Unterteilung in notwendige FSW, durch das Enden des aktuell befahrenen Fahrstreifens, oder nichtessentielle, für das Überholen eines langsameren Fahrzeuges, möglich. Weiterhin schlägt Chovan (1994) vor, Assistenzsysteme zur Unterstützung von FSW mit dem Ziel der Unfallvermeidung einzusetzen. Lee, Olsen et al. (2004) stützen diese These, da ca. 4% bis 10% aller Unfälle im Straßenverkehr auf Fahrstreifenwechsel zurückzuführen sind. FAS zur Unterstützung bei FSW benötigen Informationen über relevante Fahrzeuge in unmittelbarer Nähe des eigenen Fahrzeuges, Informationen zum benachbarten Fahrstreifen und des eigenen Fahrzeuges und Wissen über den Beginn des Fahrstreifenwechsels. Ein Assistenzsystem könnte durch leichten Brems- oder Lenkeingriff mögliche Kollisionen mit anderen Verkehrsteilnehmern verhindern oder den Fahrer warnen, eine unfallvermeidende Handlung einzuleiten, falls dieser einen möglichen Kollisionskurs eingenommen hat. Dabei sollte auch die Aufmerksamkeit des Fahrers berücksichtigt und nicht nur der Blinker zur Erkennung der Fahrstreifenwechselabsicht eingesetzt werden, da nicht jeder Fahrstreifenwechsel durch die Aktivierung des Blinkers angekündigt wird (Lee, Olsen et al. 2004). Einem Fahrmanöver gehen Merkmale und spezifische Muster voraus, welche erkannt werden können, um einen anstehenden Fahrstreifenwechsel zu identifizieren und ihn präzisieren zu können. Diese Merkmale sollten genutzt werden, den Fahrer rechtzeitig vor einer möglichen Gefahr bei der Ausführung eines FSW zu warnen. Das Wissen um den beabsichtigten Fahrstreifenwechselzeitpunkt ist dabei essentiell, um rechtzeitig warnen zu können und auch Fehlwarnungen auf ein akzeptables Maß zu senken. Die Vorhersage von Fahrmanövern ist derzeit noch nicht auf einem ausreichenden Level möglich (Diederichs 2016), weshalb eine Forschung auf diesem Themengebiet angebracht ist.

Eine Übersicht zur Fahrmanöverprädiktion ist Diederichs (2016) oder auch Doshi und Trivedi (2011) zu entnehmen. Die wichtigsten Arbeiten zur Fahrmanöverprädiktion werden im Folgenden kurz aufgeführt: Donges (1978) gelang es sehr früh, menschliches Fahrerverhalten, in diesem Fall das Lenkverhalten, zur Darstellung des Straßenfolgeverhaltens zu modellieren.

Pentland und Liu (1999) modellierten mit Hilfe von dynamischen Markov-Modellen Fahrmanöver und konnten mit Fahrzeugdaten (Geschwindigkeit, Beschleunigung, Lenkung) verschiedene Fahrmanöver präzisieren (FSW, Abbiegen, Folgefahrt, Überholen). Sie instruierten die Fahrer, die Manöver

auszuführen und erreichten ca. 2 Sekunden nach der Instruktion, was in den Versuchen mit n=47 im Fahrsimulator ca. 1,5 Sekunden nach Handlungsbeginn bedeutete, Erkennungsraten von ca. 93,3%.

Kuge et al. (2000) nutzten Hidden-Markov-Models (HMM) zur Erkennung von Fahrstreifenwechsel, Folgefahrten und Notausweichmanöver mit Hilfe von Lenkradwinkel, Lenkwinkelgeschwindigkeit und Lenkkraft. Sie trainierten das verwendete Modell mit Daten von 9 Probanden aus einer Simulatorfahrt und testeten an einem Probanden. Ihre Erkennungsraten für Fahrstreifenwechsel lagen zwischen 80% bis 100% je nach verwendeter Kombination der Eingangsgrößen zu einem Zeitpunkt von ca. 0,5 – 0,7 Sekunden nach Lenkbeginn. Eine Aussage zu Fehlerkennungsraten in anderen Situationen wurde nicht aufgeführt.

Oliver und Pentland (2000) nutzten ebenfalls HMM in einer verbundenen Form als Coupled-HMM. Die verwendeten Signale waren Fahrzeugdaten, Fahrzeugposition relativ zur Fahrstreifenmarkierung und Fahrerblickverhalten. In den verschiedenen Kombinationen erreichten sie, in Relation zu sichtbaren Veränderungen am Fahrzeug, für die Vorhersage von Fahrstreifenwechsel nach links ca. 0,1 Sekunden und nach rechts 0,7 Sekunden bei folgenden erzielten Erkennungsraten:

Tabelle 2: Ergebnisse der Fahrstreifenwechselprädiktion, Auszug aus Oliver und Pentland (2000)

	Fahrzeugdaten	Fahrzeug-& Spurdaten	Fahrzeug-& Fahrerdaten
Fahrstreifenwechsel links	29,4%	17,6%	23,5%
Fahrstreifenwechsel rechts	0,0%	12,5%	6,3%

Eine weitere Variante war die Nutzung einer kognitiven Architektur durch Salvucci et al. (2007) namens ACT-R, ursprünglich entwickelt von Anderson (1993). Sie verwendeten ein Zweipunkt Lenkmodell (Salvucci und Gray 2004) und integrierten dieses in die Architektur (Liu und Salvucci 2001). Sie verwendeten eine Receiver Operator Characteristic Analyse (ROC, vgl. Kapitel 2.4) und erreichten in einer Simulatorstudie unter erlaubter Fehlerkennungsrate von 5% aus der ROC-Analyse (Egan 1975; Metz 1978), eine Richtigerkennungsrate von 82%, 0,5s bzw. 93%, 1,0s nach dem Fahrstreifenwechselbeginn und 95% bis das Fahrzeug ein Viertel der Fahrstreifenbreite zurückgelegt hatte. Die Definition des Fahrstreifenwechselbeginns war dabei das Erreichen der definierten minimalen Lateralgeschwindigkeit von 0,35m/s vor einem Fahrstreifenwechsel. Die Auswertung einer weiteren Studie mit einem realen Versuchsfahrzeug mit demselben Modell, ergab eine Richtigerkennungsrate von 61%, 0,5s bzw. 77%, 1,0s vor Fahrstreifenwechselbeginn und 84% bis das Fahrzeug ein Viertel der Fahrstreifenbreite zurückgelegt hatte.

Bayes-Netze verwendete Gerdes (2006) um Fahrstreifenwechsel, Abbiege- und Folgemanöver auf hauptsächlich Autobahnen zu erkennen. Unter Nutzung von Fahrzeugdaten, Standortinformationen und Informationen über Herzfrequenz, Hautleitwert und Blickrichtung wurde während einer 32-minütigen Testfahrt eine Richtigerkennungsrate von 86,5% erreicht. Bei 12,7% der Zeit traten Fehlerkennungen und bei 0,8% der Fahrt trat keine Erkennung auf. Währenddessen wurden alle 20 Fahrstreifenwechsel nach links und 22 Fahrstreifenwechsel nach rechts korrekt erkannt. Zum Zeithorizont der Erkennung bzw. zur Prädiktion werden keine Angaben gemacht.

Ein Regressionsverfahren verwendet Henning (2004), vgl. auch Henning (2010a), zur Fahrmanöverprädiktion. Mit Hilfe einer Regression, unter Nutzung von manuell annotiertem Fahrerblickverhalten und Umgebungsverkehr, werden Fahrstreifenwechsel auf Autobahnen, einer Studie im Realverkehr, mit einer Erkennungsrate von 89,4% bei einer Falscherkennungsrate von 6,2%, 2,1 Sekunden vor Beginn der lateralen Bewegung, anhand des eigentlichen Datensatzes und ohne die Nutzung eines Validierungsdatensatzes, erkannt. Dabei wurden die untersuchten Prädiktoren mit Hilfe

---

von Regressionsanalysen auf Effektstärke untersucht und die Merkmale mit der stärksten Korrelation verwendet.

HMM werden von Berndt et al. (2008) zur Erkennung und Prädiktion von Fahrstreifenwechsel, Abbiege- und Folgemanöver eingesetzt. Genutzt wurden dabei Fahrzeugdaten, Abstand zum Vorderfahrzeug und Standortinformationen. Die Fahrstreifenwechsel, insgesamt bestanden die Trainingsdaten aus 100 und die Validierungsdaten aus 50 Fahrstreifenwechsel, konnten mit einer Sensitivität von ca. 71% für die Fahrstreifenwechsel nach links bzw. 74% nach rechts, unter Nutzung von Lenkwinkel und Lenkwinkelgeschwindigkeit, vor dem Überfahren der Fahrstreifenmarkierung detektiert werden. Eine genaue Angabe eines Zeithorizontes ist in dieser Arbeit nicht zu finden.

Fahrstreifenwechsel und Abbiegen detektierten Schroven und Giebel (2008) mit Hilfe von probabilistischen Ansätzen, in diesem Fall Bayes-Netze. Dazu wurden Fahrzeugdaten verwendet.

Bauer (2011) verwendet einen fahreradaptiven Algorithmus auf Basis der Fuzzy Logik, die mit Zustandsautomaten erweitert wurden, um Anhaltenmanöver im städtischen Folgeverkehr zu erkennen. Mit einer festen Wahrscheinlichkeitsschwelle und 380 Trainingsmanövern von 26 Probanden wurden Erkennungen im Zeitbereich von 4,5s bis 10,6s vor dem Anhalten, mit maximal einer Falscherkennung je Proband, erreicht.

Hülhnagen et al. (2010) beziehen in ihrer Arbeit auch zeitliche Vorhersagen zu Fahrmanövern ein. Abbiege-, Fahrstreifenwechselmanöver und Kurvenfahrten mit zeitlicher Vorhersage wurden in die Kategorien „zu früh“, „zu spät“ bei jeweils 0,25 Sekunden zeitlichem Irrtum und bei einem Irrtum ab 0,5 Sekunden als „verloren“ eingestuft. Genutzt wurde dazu ein probabilistischer Zustandsautomat in Verbindung mit Fuzzy Logik.

Morris et al. (2011) nutzen Fahrzeug-, Umfeld- und Kopfbewegungsdaten, wie auch Doshi und Trivedi (2009c), sowie noch weitere Informationen zu anderen Verkehrsteilnehmern, wie Abstand und relative Geschwindigkeitsdifferenz. Sie nutzten eine Relevance-Vector-Machine (RVM) und verwendeten zusätzlich auch abgeleitete Kopfbewegungsmerkmale, wie Histogramme und Sliding-Windows der Kopfbewegungsdaten. Sie erzielten eine Performance von  $TPR = 50\%$  bei einer  $FPR = 1\%$ , 2,5s vor einem Fahrstreifenwechsel.

Ohn-Bar et al. (2014) nutzten noch mehr Informationen der Fahrerbewegung, zusätzlich Hand- und Fußposition, Umgebungsinformationen und laterale und longitudinale Positionen der anderen Verkehrsteilnehmer, um mit einem Latent-Dynamic-Conditional-Random-Field Überholmanöver vorherzusagen. Sie erreichten dabei eine Genauigkeit von 85% beim Anfang der lateralen Bewegung vor einem Überholmanöver und 79% Genauigkeit 2s vor dem Anfang einer lateralen Bewegung.

Färber (2005) verwendet einen regelbasierten Ansatz um Abbiege-, Überhol- und Folgemanöver mit Hilfe von Fahrzeugdaten zu erkennen und erreichte dabei Richtigerkennungsraten von 93%, 93% sowie 100%. Diese Arbeit wurde von Blaschke et al. (2007) aufgegriffen und fortgesetzt. Letztere verwenden einen regelbasierten Ansatz unter Nutzung von Fuzzy Logik zur Eingangsdatenverarbeitung der Fahrzeugdaten und Standortinformationen. Sie erreichen eine Richtigerkennungsrate von 93% der insgesamt 148 ausgeführten Fahrmanöver im kontrollierten Feld unter einfachen Verkehrsbedingungen. Ein zeitlicher Vorlauf von durchschnittlich 2,3 Sekunden vor dem Überholen in Geschwindigkeitsbereichen von 80 km/h und 100 km/h wurde erreicht, die Definition des Überholbeginns ist dabei der Versatz des Fahrzeuges um 1m lateral nach erfolgter positiver Prädiktion.

Doshi und Trivedi (2009a) nutzen Kopfbewegungen und Blickrichtungen, in diesem Fall diskrete Blickziele (Oliver und Pentland 2000), um Fahrstreifenwechsel mit Hilfe von RVM zu präzisieren. Ihre Erkenntnisse sind, dass die Nutzung von Kopfbewegungsdaten in Kombination mit Fahrzeug und Daten der Position des Fahrzeuges in Relation zum Fahrstreifen, eine höhere Performance von  $TPR = 88,5\%$ , bei einer  $FPR = 0,72\%$ , 2s vor einem Fahrstreifenwechsel ergibt, als die Nutzung von Blickzieldaten

---

mit denselben Fahrzeug- und Umfeldinformationen. Sie schließen daraus, dass die Kopforientierung ein besserer Prädiktor für Fahrerverhalten darstellt, da die Information weniger Rauschen und eine höhere Konsistenz als Blickdaten beinhaltet.

Die Verknüpfung von Fuzzy Logik in einem probabilistischen Framework verwendete Schneider (2009), um Notbremsituationen und Fahrstreifenwechsel zu präzisieren.

Weitere Arbeiten verwendeten Fuzzy Logik (Poitschke 2011), dynamische Bayes-Netze (Polling et al. 2005), probabilistische Modellierung, objektorientierte HMM (Kasper et al. 2012), kontextbasierte Verhaltensmodelle (Rakotonirainy 2005), Sparse bayesian Learning (McCall et al. 2005, 2007) oder auch Mischformen, wie GMM mit Random-Forests (Börger 2012), oder eine Kombination aus Bayes-Klassifikatoren mit Entscheidungsbäumen (Hou et al. 2014).

Die Vielzahl der durchgeführten Arbeiten und die unterschiedlichen Algorithmen zeigen, dass eine Fahrmanöverprädiktion nicht nur mit einer Methode möglich ist, sondern eine hohe Anzahl an Herangehensweisen erlaubt. Auch ist in vielen dieser Arbeiten ausgewiesen, dass das Optimum der Fahrmanöverprädiktion noch nicht gefunden wurde. Der folgende Abschnitt greift die wesentlichen Algorithmen auf und beschreibt die Funktionsweise der wesentlichen Algorithmen zur Fahrmanöverprädiktion im Detail.

## 2.4. Algorithmen zur Fahrmanöverprädiktion

Algorithmen sind elementarer Bestandteil eines Systems zur Fahrmanöverprädiktion. Ein Algorithmus ist dabei eine berechenbare Abfolge von Operationen, um ein gewünschtes Ergebnis zu erhalten (Black 2004). Algorithmen besitzen die Eigenschaft von einem Computer ausgeführt werden zu können. Ein Algorithmus kann dabei von einem Menschen entworfen werden, oder von Computern mit Hilfe geeigneter Verfahren selbstständig gelernt werden. Bei solch einem **Maschinenlernverfahren** analysiert ein Computer Daten, erkennt, anhand von hinterlegten Kontextinformationen, spezifische Muster und speichert diese ab (sog. Trainings-Phase). Die gelernten Muster können dann in weiteren Schritten auf unbekannte Daten angewendet werden, um eine Bewertung dieser Daten oder eine Vorhersage von neuen Daten vorzunehmen. Maschinenlernverfahren besitzen den Vorteil, große Datenmengen in kurzer Zeit nach Zusammenhängen durchsuchen zu können und die gefundenen Merkmale für eine weitere Nutzung abzuspeichern. Generative Verfahren modellieren dabei, nach Bishop (2006), eine verbundene Wahrscheinlichkeitsverteilung einer Beobachtung mit Trainingsmarkierungen oder stellen einen Teilschritt auf dem Weg zu einer konditionellen Wahrscheinlichkeitsdichtefunktion dar. Hierunter fallen Verfahren wie Gaussian-Mixture-Models (GMM), HMM oder Naive-Bayes Klassifikatoren. Diskriminative Modelle repräsentieren die Abhängigkeit einer unbeobachteten Variablen, in Abhängigkeit von Beobachtungen durch die Modellierung der konditionellen Wahrscheinlichkeitsverteilung (Bishop 2006). Regressionen, Support-Vector-Machines (SVM), Artificial-Neural-Networks (ANN), Entscheidungs- und Regressionsbäume (decision tree / regression tree) und das Verfahren des Boosting gehören zu den diskriminativen Verfahren. Nach Bishop (2006) bilden (probabilistische) graphische Modelle mit Hilfe eines Graphen, konditionelle Abhängigkeiten zwischen Zufallsvariablen ab. Zu den Vertretern gehören Bayes Netze (BN) und Markov Netze.

Bei den Verfahren ist zwischen sogenannten Black Box und White Box Algorithmen zu unterscheiden. Black Box Algorithmen entwerfen durch das Training Strukturen und Parameter, welche keine intuitive Interpretation erlauben, wodurch das Verhalten dieser Algorithmen im Detail nicht nachvollzogen werden kann. ANN fallen in diese Kategorie. White Box Algorithmen erlauben die Interpretation der gelernten Parameter und erlauben die Funktionsweise, zum Beispiel für eine funktionelle Absicherung, nachzuvollziehen. Regelbasierte Algorithmen oder Entscheidungsbäume sind bekannte Vertreter von

---

White Box Algorithmen. Weiterhin existieren noch Verfahren, welche sich nicht vollständig zu einer der beiden Gruppen zuordnen lassen, da nur Teile von ihnen interpretierbar sind. Dieses sind die sogenannten Grey Box Verfahren, zu denen u.a. HMM gehören.

Es wird hauptsächlich zwischen überwachten (**supervised**) und unüberwachten (**unsupervised**) Maschinenlernverfahren unterschieden. Weitere Verfahren, zum Beispiel bestärkendes Lernen (reinforcement Learning) oder aktives Lernen, stellen weitere Varianten dar, welche in Bishop (2006) nachgelesen werden können, aber im Rahmen dieser Arbeit nicht weiter betrachtet werden.

### **Überwachte Lernverfahren (supervised machinelearning)**

Lernverfahren, bei denen die Trainingsdaten auch gewünschte Eigenschaften oder Werte der Zieldaten enthalten, werden überwachte Lernverfahren genannt (Bishop 2006). Bei diesen Verfahren soll ein Zusammenhang der Eingangsdaten zu den Ausgangsdaten gelernt werden, um diesen Zusammenhang auf unbekannte Daten anwenden und bewerten zu können, zum Beispiel hinsichtlich der Zugehörigkeit zu einer Klasse. Hierfür ist die Aufbereitung der Daten notwendig, um sie zur Synthese eines Algorithmus zur Fahrmanöverprädiktion nutzen zu können.

### **Unüberwachte Lernverfahren (unsupervised machinelearning)**

Unüberwachte Lernverfahren nutzen, im Unterschied zu überwachten Lernverfahren, Trainingsdaten ohne Zuordnung zu einer Zielvariablen. Dieses Verfahren soll bis dahin unbekannte Zusammenhänge in den Daten erkennen und lernen. Es ermöglicht die Identifikation ähnlicher Gruppen innerhalb der Datensätze (Clustering), die Bestimmung der Verteilung der Daten (Density estimation) oder die Projektion hochdimensionaler Daten in einen niedriger dimensionierten Raum zur Darstellung (Visualization) (Bishop 2006).

### **Klassifizierung**

Klassifizierung (Classification) ist die Methode, einen Datensatz einer endlichen Anzahl diskreter Kategorien zuzuordnen (Bishop 2006). Ein Beispiel für eine Klassifizierung ist das Erkennen eines Fahrmanövers durch die Zuordnung des Datensatzes zu einem diskreten Manöver.

### **Regression**

Regression ordnet, im Unterschied zur Klassifikation, einen Datensatz einer kontinuierlichen Variablen zu. Ein Beispiel für eine Regression ist die Berechnung des Zeithorizontes bis zum nächsten anstehenden Fahrmanöver.

### **Zeitreihen Klassifizierung**

Eine Zeitreihen Klassifizierung ist im Unterschied zu einer Klassifizierung, die Zuordnung einer Zeitreihe zu einer Klasse. Eine Zeitreihe definiert sich zu  $X = ((t_1, \mathbf{x}_1), (t_2, \mathbf{x}_2), \dots, (t_n, \mathbf{x}_n))$  (Ding et al. 2008). Das bedeutet, dass zu jedem Zeitpunkt  $t_i$  ein Vektor mit Daten  $\mathbf{x}_i$  vorliegt und dass im Unterschied zu einer Klassifizierung eines zeitlich stationären Datenvektors, bei einer Zeitreihe mehrere Elemente (insgesamt  $n$  Elemente) einer Datenquelle vorliegen. Bei der Klassifizierung von Handschriftbuchstaben anhand eines in Pixeln aufgelösten Graustufen-Bildes, kommt jeder Pixel genau einmal im Datenvektor vor. Bei der Klassifizierung von Zeitreihen, beispielsweise bei einer Fahrmanöverprädiktion, besteht der Datenvektor aus mehreren Elementen, wie der Fahrzeuggeschwindigkeit oder der Längsbeschleunigung. Zu jedem Zeitpunkt  $t_i$  liegen sowohl für die Fahrzeuggeschwindigkeit als auch für die Längsbeschleunigung jeweils ein Wert vor. Zum Zeitpunkt  $t_{i+1}$  liegen je ein weiterer Wert für die Fahrzeuggeschwindigkeit und Längsbeschleunigung vor.

---

Wesentlich dabei ist, dass die Werte nicht voneinander unabhängig sind, da diese über die Gesetze der Physik miteinander verbunden sind.

Zeitreihen können dabei mit zwei Verfahren klassifiziert werden. **Instanzbasierte Verfahren** (instance-based learning) werden häufig auch als faule Klassifizierer (lazy classifiers) bezeichnet, da diese im ursprünglichen Sinne keine explizite Trainingsphase besitzen. Ein sehr bekanntes Verfahren dieser Ausprägung ist ein Nächster-Nachbar-Verfahren (nearest neighbor, k-NN). Ein k-NN Verfahren vergleicht dabei ein Testdatenelement oder auch eine Zeitreihe mit den bekannten (Trainings-)Daten, sucht dann die  $k$  nächsten Nachbarn des Testelementes und ordnet dem Testelement die Klasse zu, die am häufigsten bei den  $k$  Nachbarelementen vorliegt. Viele Autoren postulieren, dass k-NN Verfahren mit  $k = 1$ , also 1-NN, die beste Performance liefern (Grabocka et al. 2012; Hills et al. 2014; Xi et al. 2006; Xing et al. 2012). Allerdings sind 1-NN Verfahren sehr anfällig gegenüber Ausreißern, da sich diese sehr stark negativ auf die Erkennungsleistung auswirken. Ein k-NN Verfahren ist sehr speicher- und rechenzeitaufwändig, da alle Testdaten abgespeichert werden und in jedem Rechenschritt der Abstand des Testelementes zu allen bekannten Elementen berechnet wird. Dem verwendeten Abstandsmaß kommt dabei eine große Bedeutung zu. Das Abstandsmaß beeinflusst die Performance bezüglich der Klassifikationsgüte und Rechenzeit wesentlich (Xing et al. 2010). Dabei wird am häufigsten das euklidische Distanzmaß verwendet (Xing et al. 2012). Dieses Distanzmaß ist parameterfrei und besitzt darüber hinaus eine lineare Rechenkomplexität  $O(n)$ . Nachteilig beim euklidischen Distanzmaß ist, dass es sehr sensitiv auf Rauschen in den Daten reagiert und darüber hinaus alle verglichenen Elemente oder Sequenzen dieselbe Länge besitzen müssen (Ding et al. 2008).

Ein weiteres bekanntes instanzbasiertes Klassifizierungsverfahren ist das Dynamic Time Warping (DTW). Es ist im Unterschied zu k-NN Verfahren robuster gegenüber Rauschen und Ausreißern, besitzt jedoch eine quadratische Rechenkomplexität  $O(n^2)$  (Xing et al. 2010). Details zur Funktionsweise des DTW können u.a. (Salvador und Chan 2007) entnommen werden.

Die zweite Gruppe zur Klassifizierung von Zeitreihen sind **merkmalsbasierte Verfahren** (feature based learning). Dabei wird eine Zeitreihe auf eine Anzahl von einzelnen Merkmalen reduziert und eine konventionelle Klassifizierung, wie Entscheidungsbäume, SVM oder ANN, wird zur Bestimmung der Klasse verwendet. Die einzelnen Merkmale berechnen sich häufig mit Hilfe von statistischen Verfahren. Beispielsweise wird ein Mittelwert oder Median eines verwendeten Elementes des Zeitreihenvektors gebildet, oder mit Hilfe von Fensterfunktionen werden die Daten in einen anderen Zustandsraum transformiert. Die Verfahren zum feature-based learning berechnen dabei ein Modell zur Klassifizierung vorab in der Trainingsphase und verwenden dieses gelernte Modell zur Klassifizierung von Testelementen (Xing et al. 2010). Es existieren hierbei mehrere verschiedene Ansätze. McCall et al. (2005) verwendeten ein Sliding-Window für die Berechnung der Merkmale und nutzen dann ein sparse Bayesian learning, im Detail ein SVM Verfahren. Ohn-Bar et al. (2014) wandelten mit Hilfe eines Histogramms die Datenvektoren in Verteilungsfunktionen um und verglichen dann die Testdaten mit den berechneten Histogrammen. Rodriguez und Kuncheva (2007) setzten auf intervallbasierte Merkmale und nutzten Rotation Forests, eine weiterentwickelte Variante von Entscheidungsbäumen, und SVM zur Klassifizierung. Fulcher und Jones (2014) verwendeten eine gierige (greedy) Merkmalsextraktion unter Zuhilfenahme von einer frequenzbasierten Autokorrelation, einem informationsbasierten Auswahlkriterium (Entropie) und der linearen Diskriminanzanalyse. Darüber hinaus setzten Oliver und Pentland (2000) HMM ein, um zeitliches Verhalten zu modellieren. HMM sind in der Lage dynamic-time-warping durchzuführen und eine Wahrscheinlichkeit (likelihood) der beobachteten Zeitreihe, in Bezug auf die Ähnlichkeit zu den zur Merkmalsextraktion verwendeten Zeitreihen, auszugeben. Die HMM bestehen aus verdeckten Zuständen, welche Systemzustände abbilden. Ferner bilden Initialwahrscheinlichkeiten und eine Matrix mit Übergangswahrscheinlichkeiten die Dynamik zwischen den Systemzuständen ab. Eine

---

Emissionswahrscheinlichkeitsmatrix bestimmt darüber hinaus, welche Daten die verdeckten Zustände emittieren, um den Systemzustand durch die verschiedenen Beobachtungen zu schätzen. Die Wahrscheinlichkeitsverteilung hängt bei einem HMM der 1. Ordnung dabei nur vom aktuellen Systemzustand ab (Berndt und Dietmayer 2009). Eine Hauptkomponentenanalyse zur Koordinatentransformation in maximaler Varianzrichtung und HMM verwendeten Lee und Cho (2003). Ye und Keogh (2009) nutzten Datenfragmente verschiedener Längen, sogenannte Shapelets und einen normalen Klassifizierer.

Zusätzlich zu den instanz- und merkmalsbasierten Verfahren besteht auch die Möglichkeit, Verfahren zu kombinieren, was zu hybriden Verfahren führt. Es kann darüber hinaus zwischen flachen (shallow) und tiefen (deep) Lernverfahren unterschieden werden. Bei flachen Lernverfahren berechnet ein Algorithmus direkt aus den Eingangsdaten die gewünschten Ergebnisse. Bei einem tiefen Lernverfahren werden mehrere Ebenen von Algorithmen hintereinander geschaltet, welche mit Metaergebnissen wiederum neue Ergebnisse berechnen. Das letztere Verfahren ist aktuell in der Forschung im Bereich der künstlichen Intelligenz, ein Vertreter dieser Technologie ist das Wissenssystem Watson von IBM.

### **Ensemble Learning**

Ensemble Learning ist ein Verfahren, welches Vorteile im Umgang mit verrauschten Trainingsdaten gewährt und es ermöglicht, nutzlose Trainingsdaten nicht aussortieren zu müssen (Dietterich 2002). Ein Ensemble von Klassifikatoren wird dabei aus einfachen Klassifikatoren aufgebaut, deren Ausgänge miteinander verbunden sind, um neue Klassifikationen zu ermöglichen. Der Aufbau von guten Ensembles ist eine große Herausforderung und ein aktueller Forschungsschwerpunkt bei überwachten Maschinenlernverfahren, da die Klassifikationsgüte die Leistungsfähigkeit einzelner Klassifikatoren übertrifft (Dietterich 2002). Dabei existieren drei Hauptverfahren zur Kombination der Klassifikatoren:

- Bootstrap aggregating (bagging)
- Boosting
- Stacking

**Bagging** unterteilt einen Trainingsdatensatz in möglichst gleichgroße Unterdatensätze (sog. bags) durch Resamplingmethoden (Breiman 1996). Mit jedem Unterdatensatz werden verschiedene, im Aufbau identische Klassifikatoren trainiert. Zur Klassifikation eines unbekannten Datensatzes werden dann die Ergebnisse der Einzelklassifikationen durch die Vereinigung und Auswahl der häufigsten Klassenzuordnung bestimmt.

**Boosting** arbeitet, im Unterschied zu Bagging, iterativ. Hierbei werden neue Klassifikatoren generiert, um in einem vorherigen Durchgang falsch klassifizierte Datensätze korrekt zu klassifizieren. Dadurch wird jeder Klassifikator durch die vorher aufgebauten Klassifikatoren und deren Leistungsfähigkeit beeinflusst (Freund und Schapire 1996; Schapire et al. 2002).

**Stacking** kombiniert beide Verfahren. Es werden mehrere Klassifizierer mit einem Teil der Trainingsdaten konstruiert, im Unterschied zum Bagging können hierbei verschiedene Klassifizierer verwendet werden. Die Ergebnisse der einzelnen Klassifizierer werden dann zum Training eines weiteren Klassifizierers, eines sogenannten Metaklassifizierers, genutzt. Dieser Metaklassifizierer kombiniert die Klassifikationsergebnisse der einzelnen Klassifikationen zu einem neuen (besseren) Klassifikationsergebnis.

### **Algorithmen zur Fahrmanöverprädiktion**

Im folgenden Abschnitt werden die für diese Arbeit relevanten Algorithmen im Detail erläutert.

## Neuronale Netze

Neuronale Netze, genauer gesagt Artificial Neural Networks (ANN), stellen Informationsverarbeitung, vergleichbar zu biologischen Netzen, mit Hilfe ihrer Struktur, für eine künstliche Interpretation und computergestützte Anwendungen, dar. Sie bestehen aus Neuronen, welche von der Eingangsschicht ausgehend, in mehreren Schichten, abhängig von der gewählten Komplexität, bis zu einer Ausgangsschicht vernetzt sind.




Abbildung 4: Beispielabbildung eines künstlichen Neuronalen Netzes (Bishop 2006)

Die Neuronen besitzen jeweils eine Aktivierungsfunktion, die die Aktivierung oder das Sperren der Weiterleitung von Informationen gewährleisten. Die Parametrisierung der jeweiligen Aktivierungsfunktionen jedes Neurons findet während des Trainingsprozesses statt. Das Hauptanwendungsgebiet für ANN ist Mustererkennung. ANN bieten den Vorteil nichtlineare Zusammenhänge, vergleichbar einem biologischen Lernprozess, abbilden zu können. Als Nachteil besitzen sie jedoch Black-Box Verhalten, da die gelernten Parameter keinen direkt interpretierbaren Zusammenhang zu den Daten, wie bei einem Entscheidungsbaum, besitzen. Weitere Details zu ANN sind in Bishop (2006) zu finden.

## Fuzzy Logik

Fuzzy Logik ist die Theorie zur Verallgemeinerung der klassischen binären Logik. Bei der Fuzzy Logik ist eine Aussage nicht „wahr“ oder „falsch“, sondern kann auch jeden beliebigen Wert dazwischen annehmen (Einheitsintervall, mehrwertige Logik). Zadeh (1965) veröffentlichte zuerst die Theorie von der unscharfen Logik. Fuzzy Logik eignet sich, um Unsicherheit, Vagheit und Impräzision zu beschreiben und modellieren (Kruse et al. 1994).

Fuzzy Logik ermöglicht es, menschliche Verhaltensweisen bzw. Kausalwissen durch mathematische Interpretation für einen Computer verständlich umzusetzen. Fuzzy Logik interpretiert die effiziente Art von Menschen, unpräzise Informationen zu verarbeiten. Zum Beispiel bei der Einstellung einer Heizung: „Wenn die Raumtemperatur etwas zu gering ist, drehe die Heizung etwas auf.“ Auch wird dabei dieselbe objektiv gemessene Raumtemperatur von 23°C von verschiedenen Menschen unterschiedlich eingeschätzt. Während einige Menschen diese Temperatur als angenehm empfinden, ist sie für andere Menschen vielleicht etwas zu kalt. Fuzzy Logik kann diese Unschärfe im Unterschied zu der binären Aussagenlogik aufnehmen und direkt modellieren. Fuzzymengen stellen dabei die Eingangsgrößen durch wenige Mengen dar, die dem menschlichen Verständnis besser entsprechen, als ein präziser Zahlenwert. Auch das menschliche Schlussfolgern ist weniger ein Verknüpfen von binären Aussagen, sondern entspricht eher einer regelbasierten Verknüpfung vager Aussagen (Bauer 2011). Es ist dabei möglich ein Fuzzy Modell aufzubauen, welches ein System sehr realistisch und in einer vom Menschen interpretierbaren Art und Weise darstellt. Dabei ist die Qualität des Systems umso höher, je besser die Fuzzymengen und –regeln das menschliche Verhalten abbilden (Bauer 2011).



Fuzzy Logik ermöglicht, unscharfes Expertenwissen und Erfahrungen mathematisch zu formulieren (zu repräsentieren) und von Computern zu verarbeiten. Dafür werden sog. linguistische Variablen benutzt (z.B. „sehr groß“ oder „wenig“), welche von Fuzzymengen und -regeln beschrieben werden können. Im Unterschied zu traditionellen Mengen in der Mathematik, bei denen eine Zugehörigkeit entweder als „1“ (dazugehörig) oder als „0“ (nicht dazugehörig) definiert ist, kann in der Theorie der Fuzzy Logik ein Element einen gewissen Grad an Zugehörigkeit zu einer Menge besitzen, wie „0,75“. Der Übergang ist fließend und nicht scharf. Ein Fuzzy-System besteht aus verschiedenen Elementen, welche nacheinander durchlaufen werden, um aus den Eingangsgrößen die dazugehörigen Ausgangsgrößen zu berechnen. Zuerst werden die Eingangsgrößen fuzzifiziert. Danach findet die Inferenz der Eingangsgrößen mit Hilfe der Fuzzy-Regelbasis statt und am Ende werden die Fuzzy Größen wieder auf scharfe Zahlen im Schritt der Defuzzifizierung abgebildet.




Abbildung 5: Aufbau eines Fuzzy Logik Systems

### Fuzzifizierung

Eine Menge  $F := \{(x, \mu(x)) \mid x \in G \text{ und } \mu(x) \in [0,1]\}$  heißt Fuzzymenge in  $G$ , die Abbildung  $\mu: x \rightarrow [0,1]$  wird dabei als Zugehörigkeitsfunktion  $F$  bezeichnet (Adamy 2011).

Dabei wird der Wert einer Variablen mit Hilfe einer Zugehörigkeitsfunktion auf einen Zugehörigkeitswert  $\mu$  abgebildet:  $\mu_A: x \rightarrow [0,1]$  (Kahlert 1995), dadurch wird jedem Element  $x$  der Grundmenge  $G$  der Zugehörigkeitswert  $\mu(x)$  zugeordnet. Der Zugehörigkeitswert entspricht dem Einheitsintervall  $[0,1]$  aller reellen Zahlen  $\mathbb{R}$ . Die Unschärfe der Zuordnung entspricht der Ungenauigkeit oder Ungewissheit.

Der Zustand einer Variablen kann mit Hilfe eines linguistischen Terms beschrieben werden. Zum Beispiel kann die Raumtemperatur „etwas kalt“ sein. Eine linguistische Variable beschreibt dabei den kompletten Wertebereich der Variablen durch mehrere linguistische Terme. Für die Zuordnung kann nahezu jede beliebige Funktion genutzt werden, sofern sie auf das Einheitsintervall  $[0,1]$  abbilden. Am häufigsten werden Rampen-, Dreiecks- bzw. Trapezfunktionen verwendet. Weitere beliebte Funktionen stellen die Gaußfunktion  $e^{-a(x-m)^2}$  oder die Sigmoidfunktion  $1 - \frac{1}{e^{(x-a)^2}}$  dar.

Die zuerst genannten Funktionen sind aufgrund ihrer einfachen Anschaulichkeit und durch die einfache Festlegung des Verlaufs der Funktion durch wenige Parameter (Dreiecksfunktion: 3, Trapez: 4, Rampe: 2) beliebt. Damit kann jeder Wert einer Variablen  $x$  als Zugehörigkeitsgrad  $\mu_A(x)$  der Menge  $A$  interpretiert werden. Diese Zuordnung wird Fuzzifizierung der Variablen  $x$  genannt. Im Schritt der Fuzzifizierung werden dabei alle  $\mu_{LW_{i,j}}(x_i)$  bestimmt.

### Inferenz

Ähnlich wie binäre Rechenoperationen UND (Durchschnitt), ODER (Vereinigung), NICHT (Komplement) können Schnittmengen-Operationen auf Fuzzymengen angewendet werden. Im Rahmen der Fuzzy Logik sind diese T-Normen (Adamy 2011) und müssen die Bedingungen der Monotonie, Assoziativität, Kommutativität und des Einselements erfüllen. Es können Schnittmengen (UND-Operator) oder Vereinigungsmengen (ODER-Operator) gebildet werden. Mit Hilfe von unscharfen

---

linguistischen Variablen können dann komplexe Systeme und Vorgänge mit Hilfe von Regeln beschrieben werden. Mit ihnen wird ein Zusammenhang von Eingangsgrößen eines Systems zu den Ausgangsgrößen hergestellt. In der Inferenz werden Prämissen der Eingangsgrößen mit Konklusionen der Ausgangsgrößen verknüpft. Eine Prämisse lautet zum Beispiel: „ $x$  besitzt zu einem Grad  $\mu_A(x)$  die Eigenschaft A“ und eine Konklusion: „ $y$  besitzt zu einem Grad  $\mu_B(y)$  die Eigenschaft B“. Dabei gilt, dass der Wahrheitsgehalt  $\mu_B(y)$  der Schlussfolgerung nicht größer als der Wahrheitsgehalt  $\mu_A(x)$  der Prämisse sein darf (Adamy 2011).

Diese Rechenoperationen werden in einem Fuzzy-System zu Regeln verknüpft und in einer Regelbasis abgespeichert. Die Regelbasis verknüpft im Schritt der Inferenz Eingangs- und Ausgangsgrößen des Fuzzy-Systems. Fuzzy Logik ermöglicht Experten ein System zu modellieren, wenn eine präzise mathematische Repräsentation sehr aufwändig ist. Die Regelbasis wird häufig durch Expertenwissen gestaltet. Zum Beispiel kann ein erfahrener Bediener einer Maschine, welche automatisiert werden soll, sein Verhalten zur Steuerung der Maschine in Regeln mit linguistischen Variablen  $x_i$  und linguistischen Werten  $LW_{i,j}$  aufstellen: „Wenn  $x_1 = LW_{1,j}$  und ... und  $x_n = LW_{n,l}$ , dann  $y = LW_p$ “. Diese können als Fuzzy Zugehörigkeitsfunktionen interpretiert werden, zum Beispiel: „WENN *Raumtemperatur* ist „etwas kalt“ DANN *Heizungsventil* „etwas öffnen““.

### Aggregation

Im Schritt der Aggregation werden alle UND-Verknüpfungen der Prämissen ausgeführt und aggregiert. Am geeignetsten ist dazu der Minimum-Operator:  $\mu_{agg} = \min\{\mu_{LW_{1,2}}(x_1), \mu_{LW_{2,2}}(x_2)\}$ . Dabei ergibt sich für jede Regel ein Aggregationswert im Bereich  $[0,1]$ .

### Implikation

Im Schritt der Implikation werden alle WENN ... DANN Verknüpfungen ausgeführt. Auch hier ist der Minimum-Operator sehr geeignet:  $\mu_k = \min\{\mu_{agg}, \mu_{LW_2}(y)\}$ .

### Akkumulation

Im Schritt der Akkumulation werden die Ergebnisse der Implikation  $\mu_k$  aller  $m$  Regeln miteinander verknüpft. Hierzu ist der Maximum-Operator die häufigste Wahl:  $\mu_{res}(x_1, \dots, x_n, y) = \max\{\mu_1(x_1, \dots, x_n, y), \dots, \mu_m(x_1, \dots, x_n, y)\}$ . Dieses ergibt die Zugehörigkeitsform der Ergebnisvariablen.

### Defuzzifizierung

Im Schritt der Defuzzifizierung wird aus der gewonnenen Zugehörigkeitsfunktion  $\mu_{res}$  ein scharfer Ausgangswert berechnet. Dafür eignen sich mehrere Methoden. Die geläufigsten Methoden sind die Maximum-Methode (MAX), bei der der Wert für die Stellgröße am Maximum der Zugehörigkeitsfunktion  $\mu_{res}$  genommen wird. Oftmals liegen mehrere Maxima vor, so dass dann der Mittelwert der Maxima oder Mean of Maximum (MOM) genommen werden kann. Oder es wird der Flächenschwerpunkt oder Center of Area (COA) des Integrals unter der Zugehörigkeitsfunktion berechnet, welches die genaueste der genannten Methoden darstellt, durch:  $y_{res} = \frac{\int y * \mu_{res}(y) dy}{\int \mu_{res}(y) dy}$

### Fuzzy Systeme

Fuzzy Logik besitzen, aufgrund der vorgestellten Eigenschaften, eine hohe Eignung zur Modellierung von Fahrerverhalten. Jedoch leiden Fuzzy-Systeme unter kombinatorischem Komplexitätszuwachs bei der Nutzung vieler Eingangssignale. Dadurch kann die Nutzung einer großen Anzahl von Eingangsgrößen, die Berechnung der Ausgangsgrößen in Echtzeit erschweren. Dazu existieren jedoch

Methoden zur Kontrolle der Komplexität (Krone 1995), wobei die Begrenzung der Menge der Eingangsgrößen die effektivste Variante darstellt. Ein Fuzzy System ist eine statische Abbildung der Eingangsgrößen auf die Ausgangsgrößen. Daher ist die Modellierung zeitlicher Abläufe schwierig, da der zeitliche Verlauf der Eingangsgrößen nicht direkt berücksichtigt werden kann. Im Detail bedeutet das folgendes: Ein Fuzzy System berechnet aus dem Eingangsdatenvektor die Ausgangsgrößen. Im nächsten Schritt werden aus dem neuen Eingangsdatenvektor neue Ausgangsgrößen, ohne Berücksichtigung vergangener Werte, berechnet. Eine Möglichkeit dennoch zeitliche Abläufe zu modellieren, ist die rekurrente Nutzung verzögerter Eingangs- oder Ausgangsdaten (vgl. Gorrini und Bersini 1994).




Abbildung 6: Schematische Darstellung rekurrenter Fuzzy Logik Systeme

Ein Problem bei der Nutzung rekurrenter Fuzzy-Systeme ist, dass die Ordnung des dynamischen Systems oftmals unbekannt ist und somit die Anzahl der Rückführungen abgeschätzt werden muss. Darüber hinaus vergrößert die Rückführung der Ausgangsgrößen bzw. die Verzögerung der Eingangsgrößen die Dimension der Eingangsgrößen, was direkt die Komplexität überproportional ansteigen lässt. Eine Übersicht zu rekurrenten Fuzzy Netzen ist bei Juang (2002) zu finden.

Eine weitere Methode, Fuzzy Logik den Umgang mit Zeitverläufen zu ermöglichen, ist die Kombination mit einem Zustandsautomaten, wie sie Bauer (2011) in seiner Arbeit darstellt. Dabei repräsentiert jede Regel des Fuzzy-Systems einen Zustand des Zustandsautomaten. Die Regel mit dem höchsten Aggregationsgrad gibt den aktivierten Zustand vor. Sobald eine Regel einen höheren Aggregationsgrad als die aktivierte Regel erhält, wird die Transition in einem neuen Zustand ausgeführt. Somit kann die zeitliche Aktivierung verschiedener Regeln mit Hilfe eines Zustandsautomaten abgebildet werden, ohne einen hohen Zuwachs an Komplexität zu erzeugen.

### K-Nearest-Neighbor

Das k-NN Verfahren ist ein nichtparametrisches Verfahren. Im Unterschied zum parametrischen Verfahren, bei dem eine begrenzte Anzahl von Parametern eine Wahrscheinlichkeitsverteilung repräsentieren und somit durch die Anzahl der Parameter in der Repräsentation der Wahrscheinlichkeitsdichtefunktion begrenzt ist, kann ein nichtparametrisches Verfahren eine vollständige Abbildung der Wahrscheinlichkeitsdichte, nur begrenzt durch die verwendeten Daten, ermöglichen.

Dazu werden bei einem k-NN Verfahren alle Trainingsdaten abgespeichert. Ein aufwändiges Training von Parametern ist nicht notwendig. Allerdings ist der Speicherbedarf bei großen Trainingsdatenmengen hoch.

Um mit Hilfe eines k-NN Verfahrens eine Klassifikation eines unbekannten Datensatzes durchzuführen, wird dieser Datensatz in den Funktionsraum der Trainingsdaten eingefügt. Im nächsten Schritt wird dann der Abstand des unbekannten Datensatzes mit Hilfe einer geeigneten Metrik, beispielsweise eines euklidischen Abstandsmaßes oder der Edit Distance, zu allen anderen Trainingsdatensätzen berechnet. Den unbekannten Daten wird dann die Klasse der nächsten Nachbarn zugeordnet, was auch den Namen des Verfahrens erklärt.




Abbildung 7: Schematische Funktionsraumdarstellung eines 5-Nearest-Neighbor-Verfahrens zur Klassifizierung des unbekannten Elementes  $y$

In Abbildung 7 ist der Vorgang beispielhaft dargestellt. In den Raum der Trainingsdaten mit drei verschiedenen Klassen („+“, „x“, „o“) wird ein unbekannter Datensatz „y“ eingefügt. Die Berechnung ergibt den geringsten Abstand zu 5 Elementen der Trainingsdaten, wobei  $k = 5$  die Anzahl der zu vergleichenden Nachbarn darstellt und das  $k$  im Namen des Verfahrens repräsentiert. In diesem Fall wird also ein 5-NN Verfahren dargestellt. Da drei der nächsten Elemente der Klasse „o“ angehören und dieses die Mehrzahl darstellt, wird dem unbekannten Datensatz  $y$  die Klasse „o“ zugeordnet.

Neben dem nicht vorhandenen Trainingsaufwand ist ein weiterer Vorteil, dass die Fehlerrate eines 1-NN Verfahrens mit der Annahme von  $N \rightarrow \infty$  Trainingsdaten, die Fehlerrate der Klassifikation niemals mehr als das Zweifache der minimalen Fehlerrate eines optimalen Klassifikators darstellt (Cover and Hart, 1967). Nachteil der  $k$ -NN Verfahren sind der hohe Speicherbedarf und die linear mit der Anzahl der Trainingsdaten anwachsende Rechenkomplexität zur Klassifikation. Es gibt Methoden, dieses Anwachsen durch effiziente Suchalgorithmen zu verringern, das begrenzt aber wiederum die Leistungsfähigkeit dieses nichtparametrischen Verfahrens.

### Edit Distance

Edit Distance ist ein Abstandsmaß für Zeichenketten. Dieses Distanzmaß erlaubt, zwei Zeichenketten durch die Operationen Löschen, Einfügen und Ersetzen miteinander zu vergleichen (Levensthein 1966). Weitere Varianten finden sich bei Damerau, bei dessen Distanzmaß auch das Vertauschen zweier Symbole definiert ist, um häufige Rechtschreibfehler zu adressieren (Damerau 1964). Daher wird die Levensthein-Damerau-Distanz häufig von aktuellen Algorithmen zur Rechtschreibkorrektur verwendet. Weitere Distanzmaße, wie z.B. die Hamming-Distanz, spielen eher in anderen Anwendungsfällen eine Rolle, da sie sehr spezifische Bedingungen an die zu vergleichenden Zeichenketten stellen, in diesem Fall die identische Länge beider Zeichenketten (Hamming 1950). Bei der Wortsuche in einem Dokument oder bei der Internetsuche ist es wichtig, nicht nur identische, sondern auch ähnliche Worte zu finden, um eventuelle Rechtschreibfehler ausgleichen zu können. Ein Wort stellt dabei eine Zeichenkette mit der Aneinanderreihung mehrerer Symbole dar. Die Menge aller Symbole wird dabei in der Informatik als Alphabet bezeichnet. Um bei der Wortsuche festzustellen, ob ein Wort dem gesuchten entspricht, benötigt man ein Ähnlichkeitsmaß. Mit Hilfe dessen kann quantifiziert werden, wie ähnlich das gefundene Wort dem gesuchten ist. Die Edit Distance (Levensthein 1966) wandelt dabei das gefundene Wort in das gesuchte mit Hilfe definierter Transformationsschritte um. Je weniger

---

Transformationen, im besten Fall ist das gesuchte Wort identisch und es sind Null Transformationsschritte notwendig, desto ähnlicher sind die Wörter. Jeder Transformationsschritt wird weiterhin mit definierten Kosten belegt, um unterschiedliche Transformationsschritte mit verschiedenen Kosten zu belegen. Das kann verwendet werden, um häufige Rechtschreibfehler mit geringeren Kosten zu belegen, damit die Suchergebnisse besser an den Wunsch der Suche angepasst werden können. Beispielsweise kann das Austauschen zweier Buchstaben, welche auf einer üblichen QWERTZ-Tastatur nebeneinanderliegen, mit niedrigeren Kosten versehen werden, als zwei Buchstaben, die auf der Tastatur weit auseinanderliegen. Dadurch werden häufige Rechtschreibfehler durch Verschreiben mit geringeren Kosten versehen und beeinflussen das Ergebnis der Suche nicht so stark. Das gesuchte Wort wird mit allen Wörtern des zu durchsuchenden Textes verglichen und die Wörter werden, gemäß der errechneten Abstände, aufgelistet. Die ähnlichsten Wörter können dann als Suchergebnis ausgegeben werden. Ähnlichkeiten bei der phonetischen Aussprache können ebenfalls berücksichtigt werden, in dem das Ersetzen ähnlich klingender Buchstaben mit geringeren Kosten belegt ist, als unterschiedlich klingende Buchstaben.

Edit Distance kann jedoch auch in Anwendungsfällen außerhalb der Textverarbeitung angewendet werden. Im Bereich der Mustererkennung nutzen Bunke und Csirik die Edit Distance zur Mustererkennung (Bunke und Csirik 1995). Durch ihre Arbeit kann die Edit Distance als universelle Methode zur Mustererkennung eingesetzt werden. Identifikation menschlicher Haltungen durch Videoanalyse ist ebenfalls möglich (Zhao und Liu 2009). Hoang (1993) verwendet die Edit Distance zum Vergleich von DNS-Strängen und Chua et al. (2011) identifizieren und lernen menschliche Aktivitäten in einer Smart Home Umgebung, um neue unbekannte Handlungen diesen zuordnen zu können. Die verwendete Methode ist dabei im Unterschied zu den vorher aufgezählten auch in der Lage, einen kontinuierlichen Vergleich während der Entstehung der Zeichenketten zu berechnen. Die vorherigen Varianten müssen oft beide Zeichenketten vollständig vorliegen haben, um danach eine korrekte Edit Distance berechnen zu können.

Die Umsetzung der Edit Distance in lauffähige Algorithmen durch verschiedene Autoren, wurde in der Arbeit von Navarro zusammengefasst (Navarro 2001). Hier ist beschrieben, dass die Edit Distance, häufig in der dynamischen Programmiervariante, als Wagner-Fischer-Algorithmus zur Berechnung der Levensthein-Distanz eingesetzt wird. Die Funktionsweise kann anhand eines Beispiels der Masterthesis von Sylla entnommen werden (Sylla 2015). Somit ist die Edit Distance in der Lage zur Klassifizierung von Fahrmanövern eingesetzt zu werden, wenn die Messsignale bzw. Prädiktoren in Sequenzen von Symbolen eines definierten Alphabets umgewandelt werden. Durch die Anwendung der Methoden der Fuzzy Logik ist diese Transformation gegeben.

## **Entscheidungsbäume**

Ein Entscheidungsbaum ist ein Algorithmus, der in der Lage ist, Daten zu klassifizieren. Mit Hilfe binärer Entscheidungen werden die Eingangsdaten in Form einer Baumstruktur analysiert und der Eingangsdatensatz einer diskreten Klasse zugeordnet. Ein Entscheidungsbaum wird mit Hilfe von Trainingsdaten erstellt und besteht aus Knoten und Kanten. Die Trainingsdaten werden in binäre Bereiche der Dimensionen des Eingangsdatenvektors mit Hilfe eines Entscheidungskriteriums, welches vorab durch einen Experten ausgewählt wurde, partitioniert (siehe Abbildung 8, links). Die gelernten Entscheidungsschwellen (an den Knoten) werden für die Klassifizierung unbekannter Daten genutzt und können darüber hinaus anschaulich in einer Baumstruktur (siehe Abbildung 8, rechts) dargestellt werden.




Abbildung 8: Beispiel für Entscheidungsbäume: Eingangsdatendimension (links) und grafische Struktur (rechts) aus Bishop (2006)

Die Klassifikation eines unbekannten Datensatzes wird hierarchisch und sequentiell entlang der Baumstruktur ausgeführt. An jedem Knoten wird eine Entscheidung getroffen und entsprechend der Daten des Eingangsvektors, entlang der entsprechenden Kanten weiter verfahren. Die Analyse wird bis zum Erreichen eines Endknotens ausgeführt und dem Eingangsvektor wird die Klasse des Endknotens zugeordnet. Somit ist eine Klassifikation mit geringem Aufwand möglich. Die Vorteile von Entscheidungsbäumen sind, dass die Funktion der Bewertung vollständig transparent (white-box) und die Laufzeit des Algorithmus sehr gering sind. Nachteile von Entscheidungsbäumen sind die scharfen binären Entscheidungen, wodurch die Genauigkeit der Klassifizierung eingeschränkt wird, sowie die starke Abhängigkeit von den Trainingsdaten, so dass bereits kleine Änderungen im Trainingsdatensatz zu sehr unterschiedlichen Entscheidungsschwellen und Baumstrukturen führen können.

Weitere Details zu Entscheidungsbäumen können Bishop (2006) entnommen werden.

### Regressionsbäume

Ein Regressionsbaum ist ähnlich wie ein Entscheidungsbaum aufgebaut. Der Unterschied ist, dass dieser eine Regression der Daten ausführt. Die Regression ist möglich, indem am Ende des Baumes keine diskreten Klassen hinterlegt sind, sondern Funktionen für den Verlauf der gesuchten Zielvariablen in Abhängigkeit der Eingangsgrößen. Der Wert dieser Variablen wird, beim Erreichen des entsprechenden Endknotens, durch die Berechnung der Funktion aus während der Trainingsphase definierten Eingangsgrößen berechnet. Die Vorteile der Regressionsbäume sind, identisch zu den Entscheidungsbäumen, die Transparenz, die Interpretierbarkeit sowie die geringe Laufzeit einer Regression eines unbekannten Datensatzes. Ein Nachteil von Regressionsbäumen ist, zusätzlich zu den bereits erwähnten Nachteilen von Entscheidungsbäumen, dass das Ergebnis der Regression nicht komplett stetig ist, sondern Sprünge entlang der Kanten der Entscheidungsschwellen aufweisen kann.

Die aufgeführten Algorithmen sind geeignet, Fahrmanöver mit dem Ziel einer Verbesserung von FAS zu prädictieren. Dabei sind sie auf den Informationsgehalt der Eingangsgrößen angewiesen. Im folgenden Abschnitt werden mögliche Signale und Merkmale mit ihrer Eignung zur Fahrmanöverprädiktion aufgeführt.

### Merkmale zur Fahrmanöverprädiktion

Ein Algorithmus zur Fahrmanöverprädiktion benötigt geeignete Eingangsgrößen, um Fahrmanöver prädictieren zu können. In den unterschiedlichen Arbeiten (Kapitel 2.3) wurde neben der Verwendung verschiedener Algorithmen auch auf unterschiedliche Datenquellen zurückgegriffen. Der folgende

Abschnitt beschreibt mögliche Merkmale, anhand derer eine Fahrmanöverprädiktion ausgeführt werden kann.

Bei der Fahrzeugführung erfasst der Fahrer durch seine Sinne die Umwelt. Durch Beeinflussung des Verhaltens des Fahrzeuges auf der Manöverebene will der Fahrer seine Ziele auf der Navigationsebene erreichen. Die Eingaben zur Steuerung, die dynamische Reaktion des Fahrzeuges auf die Eingaben und bestimmte Elemente der Umwelt, wie Abstand und Relativgeschwindigkeit zum Vorderfahrzeug, als auch die Blick- und Kopfbewegung des Fahrers zur Informationsaufnahme sind messbar und stehen für eine Fahrmanöverprädiktion zur Verfügung. Jedes Signal stellt eine mögliche Eingangsgröße des Algorithmus zur Fahrmanöverprädiktion dar, aber aufgrund des Prinzips der Sparsamkeit sollte das Modell, welches am sparsamsten mit der Anzahl der Hypothesen umgeht, was in diesem Fall gleichbedeutend ist mit der Anzahl der Eingangsgrößen, bevorzugt werden. Das ist auch bekannt als Occam's Razor, nach William von Occam, einem englischen Mönch und Philosophen (1288–1348) (Murphy 2012). In der Anwendung seiner Theorie bedeutet das, dass aus zwei Modellen mit demselben Generalisierungsfehler das Einfachere ausgewählt werden sollte (Domingos 1999).

Da Feature Selection einen eigenen Forschungszweig für sich darstellt, erfolgte für eine Vorauswahl von sinnvollen Eingangssignalen eine Orientierung an bekannter Literatur (Kapitel 2.3). Die verwendeten Signale können zur Ordnung und der Übersicht halber, den Elementen des FFU-Modells (Donges 1982) zugeordnet werden:

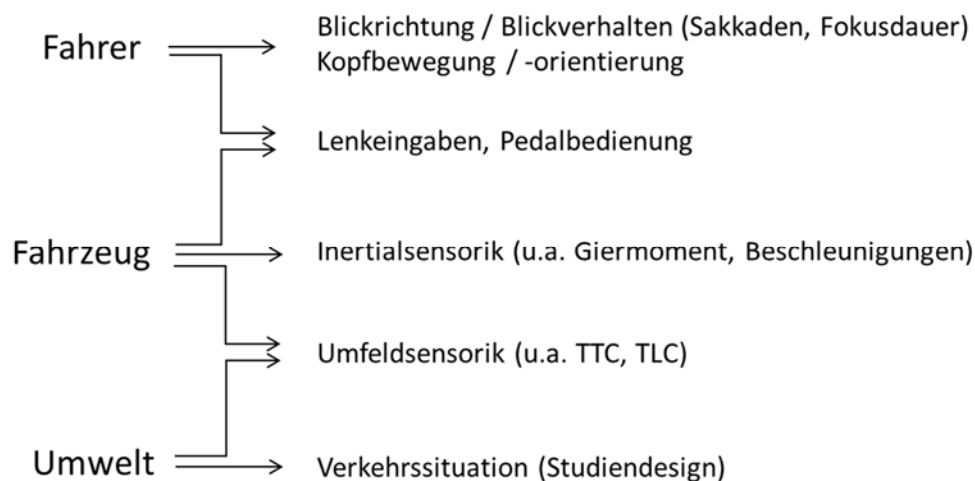


Abbildung 9: Kategorisierung von Merkmalen angelehnt an Donges (1982)

Eine Gruppe von Signalen stellen die direkt vom Fahrer messbaren Größen dar. Diese beinhalten die Blickrichtung oder Kopforientierung des Fahrers. Damit ist u.a. eine Aufmerksamkeitsrichtung abschätzbar, da die Blickrichtung mit der Informationsaufnahme korreliert (Pech et al. 2014). Über physiologische Sensoren können dabei weitere Informationen zum Fahrerzustand erfasst werden, z.B. Herzschlagfrequenz oder Hautleitwert. Diese korrelieren mit bestimmten Fahrerzuständen, welche die Ausführung von Fahrmanövern beeinflussen (Müdigkeit, Stress).

Die zweite Gruppe stellt die messbaren Signale der Bedienelemente (Lenkrad, Pedale) dar, welche der Fahrer benutzt um das Fahrzeug direkt zu führen. Mit Hilfe dieser Bedienelemente hat er direkten Einfluss auf das dynamische Verhalten des Fahrzeuges. Hiermit stabilisiert der Fahrer das Fahrzeug auf seiner Sollspur (Stabilisierungsebene) und veranlasst das Fahrzeug durch geschickte Kombination, Fahrmanöver auszuführen. Die Pedale steuert dabei die Längsdynamik des Fahrzeuges und bietet somit ein Potential Fahrmanöver mit hohem Längsführungsanteil zu präzisieren. Über das Lenkrad steuert der Fahrer dabei die Querdynamik des Fahrzeuges, was ein hohes Potential zur Prädiktion von

---

Fahrmanövern mit Querführungsanteil besitzt. Auch der Fahrtrichtungsanzeiger ist ein Stellglied, mit dem der Fahrer seinen Wunsch zum Fahrstreifenwechsel oder Abbiegen anderen Verkehrsteilnehmern mitteilt, um diese über das anstehende Manöver, zwecks Unfallverhütung, zu informieren. Jedoch wird der Blinker, trotz gesetzlicher Pflicht zur Nutzung, nicht in jeder Situation durch den Fahrer genutzt (Lee, Olsen et al. 2004). Dennoch bietet der Blinker das Potential, eine Prädiktion von Fahrstreifenwechsel positiv zu beeinflussen, da dieser zeitlich vor anderen Fahrzeugsignalen betätigt wird und somit zu einer frühzeitigen Prädiktion beitragen kann.

Die dritte Gruppe von messbaren Signalen stellt die Fahrzeugdynamik dar. Das Fahrzeug reagiert physikalisch auf die Fahrereingaben durch Änderung der Fahrzeuggeschwindigkeit, -beschleunigung oder -gierrate. Diese Signale besitzen eine hohe Zuverlässigkeit, da diese auch von stabilisierenden Assistenzsystemen, wie z.B. ESP, genutzt werden. Die Signale korrelieren stark mit der Manöverausführung, jedoch ist der Prädiktionshorizont eher gering.

Die vierte Gruppe von Signalen stellt die Relation des Fahrzeuges in seiner Umwelt dar. Diese ist durch die Position des Fahrzeuges im Fahrstreifen und durch Analyse der Fahrstreifeninformationen eines Fahrstreifenerkennungssystems möglich. Wichtige Signale sind dabei der Abstand des Fahrzeuges zur jeweilig nächsten Fahrstreifenmarkierung, der Winkel des Fahrzeuges zur jeweiligen Fahrstreifenmarkierung und die time-to-line-crossing (TLC). Die TLC berechnet mit Hilfe der Positionierung des Fahrzeuges relativ zur Fahrstreifenmarkierung und einer Kursprädiktion, wann das Vorderrad des Fahrzeuges die Fahrstreifenmarkierung berühren wird. Eine Definition und Berechnungsvorschrift finden sich u.a. in Godthelp et al. (1984). Dabei ist bei einem FSW das Vorderrad auf der Seite, zu dem der FSW gerichtet ist, relevant. Der Zeitpunkt  $t = 0s$  beschreibt dabei das Berühren der Fahrstreifenmarkierung mit dem linken Vorderrad bei einem FSW nach links.

Auch das Verhältnis des Fahrzeuges zu anderen Verkehrsteilnehmern ist ein wichtiger Indikator für die Ausführung von Fahrstreifenwechsel. So stellt ein langsamer Vorfahrer einen großen Motivator dar, dieses Fahrzeug zu überholen und den Überholvorgang durch einen Fahrstreifenwechsel einzuleiten. Mit Hilfe vom Radarsystem des ACC können der Abstand zum Vorderfahrzeug, die Zeitlücke (time headway, THW) oder die time-to-collision (TTC) genutzt werden. Definition und Erläuterung dieser Werte sind in Winner et al. (2015) zu finden.

Die fünfte Gruppe beinhaltet alle Signale, welche die Umweltbedingungen um das Fahrzeug herum beschreiben, wie die Anzahl der vorhandenen Fahrstreifen, die Topologie und weitere Umgebungseinflüsse (Wetter). Diese können mit Hilfe von GPS und Kartendaten gemessen werden. Hier finden sich Informationen, welche eine sehr frühe Prädiktion ermöglichen, aber auch mit einer sehr hohen Unsicherheit verbunden sind. Das Vorhandensein eines nutzbaren Nachbarfahrstreifens ist nur ein Motivator für einen Fahrstreifenwechsel, jedoch kein direkter Indikator. Andererseits ist jedoch das Fehlen eines benachbarten Fahrstreifens ein Inhibitor für einen Fahrstreifenwechsel.

Die Signale, welche verwendet werden sollen, um ein Fahrmanöver zu präzisieren, hängen entscheidend von der Art des geplanten Fahrmanövers ab. Es existieren Fahrmanöver mit hauptsächlich longitudinaler Veränderung der Fahrzeugdynamik, wie Anhalten oder Fahrzeug/Straße folgen. Hierzu können Signale, welche die Längsdynamik des Fahrzeuges beeinflussen, hinzugezogen werden. Diese sind vor allem die Bedienung von Gas- und Bremspedal, Werte zur aktuellen Längsbeschleunigung oder Fahrzeuggeschwindigkeit. Diese Signale versprechen den größten Informationsgehalt und die Eignung für eine Prädiktion eines Manövers mit überwiegend längsdynamischem Anteil. Fahrmanöver mit hauptsächlich lateraler Veränderung der Fahrzeugdynamik sind Fahrstreifenwechsel oder Abbiegen. Hierfür liefern Signale, welche die Querdynamik des Fahrzeuges beeinflussen oder beschreiben, die größte Aussicht auf Erfolg. Zu diesen gehören Lenkwinkel, Lenkwinkelgeschwindigkeit, Gierrate, Querbeschleunigung oder laterale Position des Fahrzeuges im Fahrstreifen (Berndt et al. 2008).



---

Allerdings sollten auch Signale der jeweils anderen Kategorie untersucht werden, um nicht gemeinsame, wesentliche Informationen auszulassen, wie ein longitudinales Verlangsamen vor einem lateralen Abbiegen.

### **Fahrzeugdaten**

Moderne Fahrzeuge bestehen aus einer Vielzahl von Sensoren und Aktoren zur Steigerung der Sicherheit, Reduktion von Emissionen und Erhöhung des Komforts. Steuergeräte übernehmen dabei die Kontrolle der Aktoren unter Nutzung der Informationen der einzelnen Sensoren. Die Steuergeräte sind zum Datenaustausch miteinander vernetzt. Die häufigste Technologie der Vernetzung ist der CAN-Bus, welcher eine serielle und zuverlässige Kommunikation der Steuergeräte ermöglicht. Durch diese Vernetzung steht allen Steuergeräten eine Vielzahl an Informationen zur Verfügung, da diese zyklisch über den CAN-Bus versendet werden. Dieser Umstand ermöglicht, zu Forschungszwecken, Signale zum Fahrzeugzustand, wie Geschwindigkeit, Lenkradwinkel oder Querschleunigung mit geringem Aufwand zu messen und für eine Fahrmanöverprädiktion zu nutzen. Viele dieser Signale besitzen eine hohe Relevanz für eine Fahrmanöverprädiktion, da diese spezifisch für verschiedene Fahrmanöver sind. Ein Abbiegemanöver ist ohne signifikante Erhöhung des Lenkwinkels nicht möglich, wodurch der Lenkwinkel die Möglichkeit eröffnet, das Fahrmanöver zu erkennen. Signale von Fahrzeugdaten ermöglichen, mit einer hohen Zuverlässigkeit Fahrmanöver zu erkennen. Der zu erwartende Zeithorizont für eine Fahrmanöverprädiktion ist jedoch als eher gering einzuschätzen. Eine Auswahl von Signalen mit der Eignung zur Prädiktion von Fahrerverhalten ist im Kapitel 4.2 zu finden.

### **Fahrerbeobachtung**

Vor allem Kopfbewegung und Blickrichtung eignen sich für eine Fahrmanöverprädiktion, da diese es ermöglichen, die Aufmerksamkeitsrichtung eines Fahrers abzuschätzen. Diese Merkmale wurden in einigen Arbeiten erfolgreich zur Fahrmanöverprädiktion benutzt (Doshi und Trivedi 2008; Lethaus und Rataj 2007; McCall et al. 2007). Sie besitzen den Vorteil, sehr frühe Merkmale zur Fahrmanöverprädiktion zu sein; als Nachteil ist allerdings die hohe Unsicherheit aufgeführt, da nicht jedem Spiegelblick auch ein Fahrstreifenwechsel folgen muss. Die Phase der Informationsaufnahme stellt dabei eine der frühesten Möglichkeiten dar, welche zur Auswertung einer Intentionsbildung und zum Start der Detektion Fahrmanöverausrührung genutzt werden können.

Weiterhin sind Sensoren zur Fahrerbeobachtung aktuell nicht in allen Fahrzeugklassen verfügbar. Sensorik zur Blickbewegungsanalyse ist darüber hinaus nicht serientauglich, da hohe Rechenleistung zur Bildverarbeitung der optischen Fahrerbeobachtungsbilder notwendig ist und die Genauigkeit im Fahrzeugumfeld, unter anderem durch wechselnde Lichtverhältnisse, nicht ausreicht, einen Mehrwert zu produzieren. Darüber hinaus werden Kameras zur Fahrerbeobachtung von einigen Fahrern, aufgrund der Beobachtung und möglichen Einschränkung ihrer Privatsphäre, nicht akzeptiert.

### **Kopfbewegungsanalyse**

Es existieren verschiedene Varianten zur Umsetzung einer Kopfbewegungsanalyse. Hauptsächlich ist zwischen intrusiven und nicht intrusiven Verfahren zu unterscheiden. Intrusive Verfahren bieten meistens den Vorteil einer hohen Messgenauigkeit von Kopforientierung und -position, während der größte Nachteil das am Kopf der untersuchten Person anzubringende Messequipment ist. Die Firma Virtual Realities LLC bietet unter dem Namen „Laserbird“ ein System, das mit Hilfe von am Kopf befestigten Marker und Laserverfahren die Position und Rotation des Kopfes berechnet.

Die nicht intrusiven Verfahren besitzen diesen Nachteil nicht, da sie oftmals die Testperson durch Kameras beobachten und die Bilder analysieren. Dieses führt zwar zu einer geringeren Detektionsqualität bezüglich der Messauflösung, ist aber aufgrund des nicht benötigten, an die Person

---

anzubringendes Testequipments, für Systeme zur Fahrerbeobachtung in Fahrzeugen deutlich zu bevorzugen. Die einfachste Methode stellt dabei das Verfahren dar, bei dem aktuelle Kamerabilder der Person mit gespeicherten und gelabelten Vergleichsbildern von Kopfpositionen verglichen werden und der Kopfrotationswinkel des ähnlichsten Vergleichsbildes ausgegeben wird. Dieses Verfahren heißt auch appearance-based headtracking und wurde in der Arbeit von Niyogi und Freeman (1996) verwendet. Ein weiteres Verfahren ist das Pose-similarity-ratio headtracking. Sherrah et al. (2001) setzen dieses ein und es erweitert das appearance-based headtracking um die Hauptkomponentenanalyse. Eine Methode mit sogenannten Detecto-arrays verwendeten Huang et al. (1998) in Verbindung mit SVM zur Kopfpositionsschätzung. Im Bereich der nichtlinearen Regression eignet sich ein Verfahren zur Verwendung von Support-Vector-Regression (SVR, vgl. SVM) und Histogrammen nach Murphy-Chutorian et al. (2007). Eine andere Herangehensweise bieten geometrische Verfahren. Sie analysieren geometrische Eigenschaften des Fahrers, wie Augenabstand oder Position der Nase in Relation zu den Augen, um Kopfbewegungen zu erkennen (Horprasert et al. 1997). Xiao et al. (2003) erweiterten dieses Verfahren, in dem sie nicht nur ein Bild der Person betrachten, sondern mehrere, zeitlich aufeinanderfolgende Bilder und mit Hilfe des Lucas-Kanade Algorithmus analysierten. Dieses Verfahren ist als Geometric Headtracking bekannt. Weiterhin bietet die Firma SmartEye ein System zur kamerabasierten Kopf- und Blickbewegungsanalyse an. Dieses System kombiniert die Verfahren des appearance-based, detector array und geometric headtracking.

### **Blickbewegungsanalyse**

Wie bei den Verfahren zur Kopfbewegungsanalyse ist hier zwischen intrusiven und nichtintrusiven Messverfahren zu unterscheiden. Die Unterschiede bzw. Vor- und Nachteile gestalten sich analog zu den Systemen zur Kopfbewegungsanalyse. Partiiell sind die Auswirkungen jedoch noch stärker, da teilweise Objekte (Kontaktlinsen) auf der Augenoberfläche platziert werden, was eine Versuchsdauer von unter 30 Minuten bedingt. Eine gute Zusammenfassung ist bei Heide et al. (1999) zu finden.

Die intrusiven Verfahren bestehen hauptsächlich aus kontaktlinsenbasierten Verfahren, bei denen die Personen Messlinsen eingesetzt bekommen, um die Blickrichtung zu messen. Diese Verfahren zeichnen sich durch ein sehr gutes Signal-Rausch-Verhältnis (signal to noise ration, SNR) aus und besitzen eine hohe Messauflösung bezüglich der Blickrichtung von bis zu  $0,03^\circ$  Augenrotation. Nachteile sind, neben dem intrusiven Messverfahren, auch die geringe Haltbarkeit der verwendeten Linsen, welche teilweise nach wenigen Versuchen ersetzt werden müssen. Ein weiteres intrusives Verfahren ist die Elektrooculographie. Sie besitzt ebenfalls hohe Winkelauflösung von bis zu  $1^\circ$  und ist sehr robust gegenüber dem Tragen von Brillen oder dem (teilweisen) Schließen der Augenlider. Sie besitzen auch höheren Tragekomfort als Verfahren mit Kontaktlinsen. Jedoch existieren Probleme bei der Erkennung unter starkem Lichteinfall, wie Sonnenlicht, und die Messung wird durch elektromagnetische Felder, wie sie verstärkt in Fahrzeugen auftreten, beeinflusst.

Ein nicht intrusives Verfahren zur Blickbewegungsanalyse ist die Videooculographie. Hierbei wird der Kopf der Testperson mit Hilfe von Kameras aufgezeichnet und durch Analyse von Kopf- und Augenmerkmalen und Reflexionen die Blickrichtung berechnet. Es besticht durch das Fehlen intrusiver Elemente und besitzt ein ähnlich hohes Auflösungsvermögen wie die Elektrooculographie. Nachteile sind jedoch neben den hohen Kosten auch die aufwändige Installation (Pech et al. 2014). Weiterhin verschlechtern schnell wechselnde Lichteinflüsse oder direktes Sonnenlicht die Performance. Darüber hinaus ist die Leistungsfähigkeit der Blickbewegungsanalyse bei Personen mit Brillen reduziert und unter bestimmten Bedingungen teilweise nicht möglich (Henning 2010b).

Im Bereich der Blickbewegungsanalyse können verschiedene Muster beim Menschen unterschieden werden. Das Blickverhalten gliedert sich dabei hauptsächlich in Fixationen und Sakkaden. Fixationen zeichnen sich dadurch aus, dass sie eine stabile Orientierung der Blickrichtung aufweisen mit einer

---

Winkelabweichung von kleiner  $1^\circ$  und einer geringen Blickbewegungsgeschwindigkeit von unter  $100 \frac{^\circ}{s}$ . Sie dauern minimal 200ms und dienen der visuellen Informationsaufnahme (Salvucci und Goldberg 2000). Da der Mensch nur im Bereich zwischen  $1-5^\circ$  eine hohe Auflösung seines Sehvermögens besitzt, ist eine gezielte Informationsaufnahme nur in diesem Bereich möglich, wodurch beim Menschen in 90% der Zeit des Sehens Fixationen vorliegen (Duchowski 2007).

Sakkaden zeichnen sich hauptsächlich durch eine hohe Blickbewegungsgeschwindigkeit von über  $100 \frac{^\circ}{s}$  aus (Nyström und Holmqvist 2010) und besitzen dabei kürzere Dauern als Fixationen. Sakkaden dauern vorwiegend weniger als 100ms (Duchowski 2007). Ein Mensch verwendet Sakkaden um über sein Sichtfeld zu „scannen“ und alle für ihn relevanten Elemente einer Szene aufnehmen zu können. Dabei ist er während einer Sakkade praktisch blind (Duchowski 2007).

Einige Studien haben typisches Fahrerblickverhalten betrachtet und analysiert (Olsen et al. 2005; Tijerina et al. 2005). Diese kommen zu dem Schluss, dass Fahrstreifenwechsel in überwiegender Anzahl mit mindestens einem Blick in den Innen- oder einen der Außenspiegel begleitet wird. Zeitlich finden die Blicke überwiegend in der Vorbereitungsphase der Fahrstreifenwechsel statt, stellen also frühe Indikatoren für dieses Manöver dar. Allerdings treten Blicke in die Spiegel so häufig auf, dass fahrstreifenwechselbezogene Blicke nahezu versteckt sind (Takahashi und Akamatsu 2008). Dieses Phänomen wird von Doshi und Trivedi (2009c) ebenfalls festgestellt und als „Noisiness“ bezeichnet. Vor allem treten diese Rückspiegelblicke vermehrt auf, wenn Fahrzeuge dem eigenen Fahrzeug in unmittelbarer Nähe folgen (Henning et al. 2009). Darüber hinaus sind auch nicht alle Blicke zweckgebunden im Sinne einer Orientierung für ein anstehendes Fahrmanöver. Sie können auch durch externe Stimuli, wie plötzlich in der Umgebung auftauchende Objekte, hervorgerufen werden. Dabei verstärken markante Farben, Intensität oder Bewegung die Anziehungskraft, diese Objekte zu betrachten (Achieser 2016). Doshi und Trivedi (2009b) haben diese Herausforderung adressiert, indem sie sogenannte „Salience-Maps“ eingeführt haben, welche die Ablenkung durch Fahrmanöver unrelevanter Objekte reduzieren soll. Falls ein Objekt durch einen Algorithmus zur Bestimmung des optischen Flusses als hervorstechend (salient) klassifiziert und ein Fahrerblick in die Nähe dieses Objektes festgestellt wird, so wird dieser als Blick auf das Objekt und nicht als manöverrelevant definiert.

### **Bewertung der Fahrerbeobachtungsverfahren**

Die Nutzung von Kopfbewegungsdaten besitzt Vorteile gegenüber der Nutzung von Blickbewegungsdaten. Sie ist mit Hilfe günstigerer Hardware und geringeren Kosten möglich (Asteriadis et al. 2014; Nabati und Behrad 2010), was einen wesentlichen Treiber für die Implementierung in Serienapplikationen darstellt. Weiterhin ist die Robustheit der Kopfbewegungsmessung höher als die Blickbewegungsmessung. Dieses konnte auch in einer Probandenstudie zur Aufzeichnung von Daten zur Fahrmanöverprädiktion (vgl. Kapitel 4.3 und Abbildung 26) festgestellt werden. Auch der Informationsgehalt von Kopfbewegungen ist höher, da häufig weniger Kopfbewegungen auftreten, welche nicht durch die Vorbereitung oder Ausführung eines Fahrmanövers motiviert sind. Spiegelblicke treten auch auf, um das Situationsbewusstsein aufrecht zu erhalten und relevante Objekte in der Umgebung zu verfolgen und mental abzubilden (Mourant und Donohue 1977). Jedoch erlaubt die Kopforientierung eine geringere Genauigkeit in der Aufmerksamkeitsrichtung, da die Augen in gewissen Grenzen unabhängig vom Kopf bewegt werden können und dieses in einem schmalen Bereich auch als komfortabel angesehen wird. Daher korreliert die Kopfbewegung auch in hohem Maße mit der Blickbewegung und kann somit als stellvertretendes Merkmal herangezogen werden (Henning 2010b). Stiefelhagen und Zhu (2002) haben herausgefunden, dass der Kopfwinkel über 50% bis zu 96% zum Blickwinkel beiträgt und mit Hilfe der Kopfbewegung Blickziele mit einer Genauigkeit von 88,7% richtig vorhergesagt werden können. Pech et al. (2014) fanden bei ihrer Analyse von Fahrerblickverhalten in Bezug auf definierte Areas-of-Interest, mit Hilfe

eines Naive-Bayes Klassifizierers, eine Übereinstimmung von 70% zwischen Blickverhalten und Kopfdrehung für den linken Außenspiegel und 81% für den rechten Außenspiegel.

Diese Untersuchungen lassen den Schluss zu, dass die Kopfbewegungsanalyse eine ähnlich gute Performance zur Fahrmanöverprädiktion erlauben kann wie eine Blickbewegungsanalyse. Das liegt in der hohen Korrelation der Kopfbewegung mit dem Aufmerksamkeitsfokus und der höheren Robustheit begründet. Weiterhin besitzt die Kopfbewegungsanalyse durch eine früher zu erwartende Serieneinführung, aufgrund von finanziellen Aspekten, die Möglichkeit, diese Daten bereits in naher Zukunft für FAS nutzen zu können. Die Blickbewegungsanalyse ermöglicht, im Unterschied zur Kopfbewegungsanalyse, die genauere Erkennung von Blickzielen und Aufmerksamkeitsrichtung, was in einem vergrößerten Zeithorizont zur Fahrmanöverprädiktion, bei reduzierter Robustheit, resultieren kann.

### Physiologische Daten

Es gibt noch weitere Methoden, Merkmale zur Fahrmanöverprädiktion zu sammeln. Diese bestehen hauptsächlich aus Daten von physiologischen Sensoren. Die Informationen von physiologischen Sensoren beinhalten die Erkennung der Atemfrequenz, eine Sprachanalyse, die Messung von Herzfrequenz und Hautleitwert, die Analyse von Mimik und Gestik sowie weitere Messwerte wie Sauerstoffaufnahme oder Blutzuckergehalt. Diese Werte korrelieren gem. Kopf (2005) nicht direkt mit der Fahrerabsicht, sondern hauptsächlich mit der kognitiven und körperlichen Belastung oder der Wachsamkeit. Da die Aufnahme dieser Daten im Fahrbetrieb nur mit sehr hohem Aufwand möglich ist und eine Korrelation nicht direkt vermutet werden kann, werden physiologische Daten für die weitere Analyse nicht betrachtet.

Nachdem mögliche Algorithmen und Eingangsgrößen aufgezeigt wurden, ist ein Maßstab für den Vergleich verschiedener Algorithmen oder Konfigurationen aus Eingangsgrößen notwendig. Dazu werden im folgenden Abschnitt einige geeignete Maßstäbe präsentiert und erläutert.

### Bewertung von Klassifikation

Zur Bewertung eines binären Klassifikators wird die Wahrheitsmatrix eingesetzt. Diese kann aufgestellt werden, solange man Informationen über das wahre Auftreten einer zu bewertenden Eigenschaft der Daten besitzt. Eine Klassifikation ist dabei ein Test, ob diese Eigenschaft in den Daten vorhanden ist. Da in nahezu allen Fällen eine reale Klassifikation zu 100% nicht richtig zugeordnet, muss die Klassifizierungsleistung gesondert analysiert werden. Bei einer binären Klassifikation können die folgenden vier Fälle auftreten:

Tabelle 3: Beispiel einer Wahrheitsmatrix

	Datum gehört zur Klasse	Datum gehört nicht zur Klasse
Test ordnet Datum der Klasse zu	Richtig Positiv / true positive (TP)	Falsch Positiv / false positive (FP)
Test ordnet Datum nicht der Klasse zu	Falsch Negativ / false negative (FN)	Richtig Negativ / true negative (TN)

Gehört ein Datensatz zu einer Klasse, also wird ein Datensatz eines Fahrstreifenwechsels (FSW) analysiert und der Klassifikator ordnet diesen Datensatz der Klasse FSW zu, so ist die Klassifikation richtig positiv. Wird derselbe Datensatz als kein FSW klassifiziert, so liegt eine falsch negative Klassifikation vor. Würde der Klassifikator einen anderen Datensatz, welcher kein FSW ist, als FSW

klassifizieren, so liegt eine falsch positive Klassifikation vor. Wird dieser Datensatz als kein FSW klassifiziert, so ist diese Erkennung richtig negativ.

Im nächsten Schritt wird die Wahrheitsmatrix mit Ergebnissen der Klassifikation befüllt. Zur Beurteilung eines Klassifikators, unabhängig von der Stichprobe, ist dann die Berechnung der relativen Häufigkeiten notwendig. Dabei sind zwei Werte in der statistischen Analyse eines Klassifikators von besonderer Relevanz. Die Sensitivität stellt die Richtig-Positiv-Rate (true-positive-rate, TPR) eines Klassifikators dar, was die Menge der richtigerweise als korrekt klassifizierten Daten, auf die Menge der tatsächlich richtigen Zuordnungen bezieht. Sie berechnet sich zu:  $TPR = \frac{TP}{TP+FN}$

Der zweite Wert, welcher als Spezifität bezeichnet wird und die Falsch-Positiv-Rate (false-positive-rate, FPR) des Klassifikators beschreibt, beinhaltet die richtigerweise als negativ klassifizierten Daten, bezogen auf die Menge der tatsächlich negativen Fälle. Sie berechnet sich zu:  $FPR = \frac{FP}{TN+FP}$

### ROC Kurve

Die Receiver Operator Characteristic (ROC) Kurve erlaubt es, einen binären Klassifizierer bezüglich der Spezifität und Sensitivität grafisch darzustellen und zu bewerten. Dazu wird die Sensitivität über der Falsch-Positiv-Rate, was  $1 - \text{Spezifität}$  entspricht, aufgetragen. Eine Kurve erhält man dabei durch die Variation des Entscheidungskriteriums, welches die Klassengrenze definiert. Bei einer kontinuierlichen Berechnung einer Eintrittswahrscheinlichkeit kann das Entscheidungskriterium durch einen Wert dargestellt werden, oberhalb dessen eine binäre Klassifikation den Datensatz als der Klasse zugehörig einordnet.




Abbildung 10: Fiktives Beispiel einer ROC-Kurve aus Sylla (2015)

In Abbildung 10 ist eine ROC-Kurve eines fiktiven Klassifikators dargestellt. Die gestrichelte Diagonale ist die Referenz für die Bewertung, da sie die Qualität eines idealen Zufallsklassifikators darstellt. Dieser würde zu jedem abgefragten Zeitpunkt die Klassifikation vollkommen zufällig wählen und wäre somit der schlechteste mögliche Fall einer Klassifikation. Verläuft die Kurve des Klassifikators oberhalb der Diagonalen, ist diese Klassifikation besser als der Zufall und besitzt somit einen höheren Informationsgehalt. Verläuft die Kurve eines Klassifikators unterhalb der Diagonalen, so ist auch dieser Klassifikator besser als ein Zufallsprozess, jedoch sollte der Ausgang invertiert werden, wodurch die

Kurve an der Diagonalen gespiegelt würde und in eine geeignetere Darstellung überführt wird. Ein optimaler Klassifikator sagt in allen Fällen eine Klasse richtig vorher und erzielt keine Fehlerkennung. Dieser Fall wird durch einen Punkt links oben im Graphen repräsentiert. Ein realer Klassifikator weist in nahezu allen Fällen eine  $TPR < 100\%$ , bei einer  $FPR > 0\%$  auf und so ergibt sich ein Verlauf, ähnlich der Darstellung in Abbildung 10. Der optimale Punkt des Klassifikators liegt dabei an der Stelle mit dem größten Abstand zur Diagonalen bzw. mit dem geringsten Abstand zur Koordinate (1,0). Dieser Punkt ist in der Abbildung mit einem schwarzen Punkt markiert.

### Area-under-Curve

Ein weiterer Maßstab zur Bewertung, welcher direkt aus der ROC abgeleitet werden kann, ist die Fläche unter der ROC-Kurve einer Klassifikation. Sie wird als Area-Under-Curve (AUC) bezeichnet. Eine größere Fläche beschreibt dabei einen besseren Klassifikator. Der schlechteste Wert ist der Wert eines idealen Zufallsprozesses mit  $AUC = 0,5$ . Ein idealer Klassifikator erreicht einen Wert von  $AUC = 1,0$ .

### Bewertung der zeitlichen Prädiktion

Bei der Prädiktion von Fahrmanövern spielt der Prädiktionshorizont, also der Zeitpunkt bis zum Erreichen eines wesentlichen markanten Punktes des Fahrmanövers, eine große Rolle. Das bedeutet, man muss zur Abschätzung einer Performance die zeitliche Prädiktion ebenfalls bewerten, was mit einer ROC-Analyse nicht möglich ist. Es bietet sich an, den optimalen Punkt des Tradeoff eines binären Klassifikators zu verwenden und an diesem Punkt die jeweilige Prädiktion des Zeithorizontes zu betrachten. Analysiert man die Ergebnisse eines Klassifikators daraufhin, so ergibt sich für jede richtige Klassifikation eine Zeitdauer, in der die Klassifikation vor der Manövermarkierung korrekt durchgeführt wurde. Diese Zeitdauer kann dann mit Hilfe von bekannten deskriptiven statistischen Werten, wie dem Mittelwert oder dem Median, beschrieben werden. Ein großer Zeithorizont bedeutet dabei, dass die Information über ein bevorstehendes Fahrmanöver einem FAS früher zur Verfügung gestellt werden kann, was die Effektivität dieses FAS deutlich steigert. Daher ist ein möglichst großer Zeithorizont anzustreben. Dieser Wert kann jedoch nicht in die Unendlichkeit gesteigert werden, sondern hängt von den Eigenschaften der Daten ab. Bei der Analyse der Daten ist eine Beschränkung auf ein Zeitfenster angemessen, um Merkmale, welche nicht zu einem Fahrmanöver gehören, auszuschließen, um somit ein Übertraining (overfitting) eines Maschinenlernverfahrens zu verhindern. Weiterhin treten Merkmale zur Prädiktion von Fahrstreifenwechsel nicht Minuten vor dem Fahrmanöver auf, sondern erst wenige Sekunden vor der Manöverausrührung, wie ein Schulterblick oder die Aktivierung des Fahrtrichtungsanzeigers.

Weiterhin kann auch die Abweichung des prädizierten Zeithorizontes vom wahren Zeithorizont der Daten verwendet werden, zum Beispiel in Form der quadratischen Abweichung. Zur Berechnung der mittleren quadratischen Abweichung kann folgende Formel aus Sylla (2015) verwendet werden:

$$t_{h,err} = \frac{1}{t_{h,max}} \int_{t_m - t_{h,max}}^{t_m} (t_h(t) - t_{h,real}(t))^2 dt$$

Der quadratische Fehler der Prädiktion des Zeithorizontes  $t_{h,err}$  berechnet sich aus dem maximal möglichen Zeithorizont  $t_{h,max}$ , dem realen Wert des Zeithorizontes  $t_{h,real}$ , welcher durch Markierungen in den Trainings- und Testdaten vorgesehen sein muss, dem Zeitpunkt des Referenzpunktes des Fahrmanövers  $t_m$  und dem prädizierten Zeithorizont  $t_h$ .

### Probandenevaluierung

---

Eine Variante zur Leistungsabschätzung eines Systems stellt ein Test mit Hilfe von Probandenevaluation dar. Dieses ist insbesondere bei Systemen mit direktem Kontakt zu Nutzern geeignet. Dabei wird eine prototypische Umsetzung eines entwickelten Systems mehreren Probanden unter kontrollierten Bedingungen zum Test zur Verfügung gestellt. Den Probanden werden dabei Aufgaben gestellt, die mit dem System oder mit Unterstützung durch das System, durchgeführt werden sollen. Dabei wird das Verhalten während des Versuches überwacht und den Probanden werden nach der Ausführung einzelner Aufgaben und zum Ende des Versuches Fragen zum Umgang mit dem System gegeben. Mit Hilfe verschiedener Metriken können dann Aussagen zum System gesammelt und die Eignung oder Akzeptanz einer Nutzergruppe abgeschätzt werden. Nachteilig ist hierbei, dass für diese Art der Evaluation ein evaluierbares System prototypisch aufgebaut oder umgesetzt werden muss.

## **Validierung**

Validierung beschreibt die Methodik, mit der bewertet wird, ob ein Verfahren den gestellten Anforderungen entspricht. Um einen Algorithmus des Maschinenlernens in seiner Performance zu validieren, wird ein Datensatz in Trainings- und Testdaten aufgeteilt. Ein statistisches Modell oder Algorithmus wird dann mit Hilfe von Maschinenlernverfahren mit dem Trainingsdatensatz trainiert, zum Beispiel werden bei einer Regression die Koeffizienten der Regressionsgleichung ermittelt und die Performance an dem Testdatensatz, welcher dem Algorithmus bis dahin unbekannt ist, ermittelt. Die geeignete Größe der Aufteilung beträgt 70% Trainingsdaten und 30% Testdaten (Adamy 2011). Da durch dieses Verfahren nicht die komplette Datenmenge zum Training des Algorithmus verwendet wird, ist die Aussage der Performance eines Algorithmus, aufgrund der reduzierten Trainingsdaten, nicht vollständig. Ein Training und Testen an denselben Daten ohne Trennung gibt jedoch keinen verlässlichen Anhalt über die Performance, da dieses das Problem der Überanpassung (sog. Overfitting) nicht berücksichtigt. Für parametrische Verfahren bietet sich auch die Nutzung eines Informationskriteriums, wie das Bayes Informationskriterium an, um die Güte eines statistischen Modells zu bestimmen. Für eine zu geringe Anzahl von Trainingsdaten und für nichtparametrische Modelle ist dieses jedoch nicht möglich.

## **Kreuzvalidierung**

Um die Herausforderungen der Validierung zu adressieren, gibt es die Methode der Kreuzvalidierung. Kreuzvalidierung ist ein Verfahren, um die Fähigkeit der Generalisierung eines statistischen Modells abzuschätzen, auch über die Trainingsdaten hinaus. Es bestimmt eine mittlere Vorhersagegüte, um eine realistischere Abschätzung der Vorhersageperformance eines Modells zu erhalten. Dabei kann das Verfahren in zwei Gruppen unterteilt werden. Zum einen, die vollständigen (exhaustive) Verfahren zur Kreuzvalidierung und zum anderen, die Verfahren zur nicht vollständigen (non-exhaustive) Kreuzvalidierung. Dazu werden, wie auch bei konventionellen Verfahren zur Validierung im Maschinenlernen, ein Trainings- und ein Testdatensatz verwendet. Bei den vollständigen Verfahren, wie Leave-p-out (LPOCV) oder Leave-one-out cross validation (LOOCV), ist eine sehr hohe Anzahl an Trainingsdurchläufen des Algorithmus notwendig, da bei der LOOCV ein Datensatz aus der Gesamtmenge entfernt wird, mit den restlichen Daten der Algorithmus trainiert wird und die Performance wird an dem entfernten Sample bestimmt. Vor allem bei LPOCV entsteht eine binomiale Anzahl an Durchläufen, was zeitlich selten zu bewältigen ist. LOOCV benötigt dahingegen „nur“ so viele Trainingsdurchläufe, wie der Datensatz Untersätze enthält. Dieses Verfahren kommt einem Einsatz eines Assistenzsystems im Fahrzeug oder anderen Algorithmen zur Prädiktion von menschlichem Verhalten sehr nahe; dieses System wird an vielen (Probanden-) Daten trainiert und dann an einem Fahrer bzw. Nutzer getestet. Die Performanceaussage ist also für diese Fälle sehr realistisch. Weiterhin werden bei dem LOOCV alle Datensätze in Kombination benutzt, wodurch sparsam mit den vorhandenen Trainingsdaten umgegangen wird, da diese vollständig zur Abschätzung der Leistungsfähigkeit von Algorithmen berücksichtigt werden. Darüber hinaus gibt es noch die nicht

---

vollständigen Verfahren zur Kreuzvalidierung, welche nicht unter der hohen Anzahl von Trainingsdurchläufen leiden und daher eine effiziente Performanceabschätzung erlauben, dabei allerdings nicht die maximale Anzahl an Trainingsdaten ausnutzen und somit automatisch eine Verzerrung (Bias) der Performanceabschätzung beinhalten, im Unterschied zu vollständigen Verfahren zur Kreuzvalidierung. Bei der  $k$ -fold Kreuzvalidierung werden die Daten in  $k$  möglichst gleichgroße Teilmengen (folds) aufgeteilt. Dann wird ein Algorithmus mit  $k - 1$  Daten trainiert und die Performance an der weiteren Teilmenge getestet. Die Anzahl der Durchläufe ergibt sich aus der Anzahl der Teilmengen  $k$ . Übliche Größen für  $k$  sind vier, fünf oder zehn. Bei  $k = 4$  und  $k = 5$  ist die Verteilung zwischen Trainingsdatensatz und Testdatensatz ähnlich wie bei normaler Validierung, somit ist das Verhältnis ausgewogen. Eine weitere Variante der Kreuzvalidierung ist das wiederholte, zufällige Auswählen der Trainings- und Testdaten in jedem Schritt, welches auch als Monte Carlo Kreuzvalidierung bekannt ist. Da hierbei in jedem Durchlauf die Trainings- und Testdaten zufällig aus der Gesamtmenge gezogen werden, kann es passieren, dass einige Datensätze deutlich seltener, bis hin zu gar nicht, verwendet werden.

Nach der Berechnung der Performance-Metriken in jedem Einzelschritt der Kreuzvalidierung werden, zur Gesamtbeurteilung eines Algorithmus, die berechneten Einzelwerte je Validierungsschritt gemittelt und man erhält eine Abschätzung der Performance des validierten Algorithmus, bezogen auf eine mögliche, generalisierte Anwendung außerhalb des bekannten Datensatzes.

## **2.5. Entwicklungsprozesse zur Algorithmenentwicklung**

Die zielgerichtete Entwicklung eines Algorithmus sollte sich an bekannten Methodiken orientieren, da diese Methoden eine Entwicklung systematisch beschreiben, einen optimierten Ablauf zur Zielerreichung beinhalten und Werkzeuge bereitstellen, um das Entwicklungsrisiko zu minimieren. Mögliche Entwicklungsprozesse sind im folgenden Abschnitt erläutert. Prozesse zur Entwicklung interaktiver Systeme beinhalten folgende gemeinsame Schritte: Nach einer Ermittlung von Anforderungen an das System werden mögliche Gestaltungslösungen entwickelt, im folgenden Schritt evaluiert und mit Hilfe der Ergebnisse der Evaluierung die Gebrauchsfähigkeit des entwickelten Systems als ausreichend bewertet und das System wird freigegeben. Im Fall zyklischer Entwicklungsprozesse wird mit der nächsten Iteration zur Verbesserung gestartet (vgl. auch Franz 2014).

Mögliche Entwicklungsprozesse können gem. König (2012) in vier Hauptgruppen unterteilt werden. Diese vier Gruppen sind in Tabelle 4 dargestellt.



Tabelle 4: Vergleich von Vorgehensmodellen aus König (2012)

	Sequentielle Modelle	Iterative Modelle	Prototypische Modelle	Nutzerfokussierte Modelle
Alternative Bezeichnungen, Vertreter	Wasserfall-Modell Stufenmodell	Zyklisches Modell Inkrementelles Modell		Participatory / User Centered Design Nutzer-/ menschenzentrierter Gestaltungsprozess
Vertreter	Phasenmodell (Benington, 1987) Wasserfall-Modell (Royce, 1970)	Spiralmodell (Boehm, 1988) Iteratives Verbesserungsmodell (Basili & Turner, 1975)	Spiralmodell (Boehm, 1988)	DIN EN ISO 9241-210 Scenario-based usability engineering (Rosson & Carroll, 2002) Usability Engineering Lifecycle (Mayhew, 1999) Prozessmodell „Usability Engineering“ (Sarodnick & Brau, 2006)
Eigenschaften	Sequentiell, mehrere Schritte Übergang nach Abschluss einer Phase Ergebnisse je Phase = Meilensteine, werden weiter verwendet Anforderungen werden zu Beginn vollständig ermittelt, bilden Basis für den Entwurf	Entwicklung in Inkrementen Kontinuierlich oder stufenweise Fertigstellung bzw. Erweiterung z. T. mit Risikoanalyse Dynamische Reaktion auf neue Erkenntnisse Anforderungen in Teilmengen aufgeteilt und realisiert, wenig Abhängigkeiten	Phasen werden wiederholt durchgeführt aufgrund der Erfahrungen mit den Prototypen Unterschiedliche Arten von Prototypen abhängig von jeweiliger Aktivität	Iterativ Integration der zukünftigen Anwender und anderer Stakeholder in eine oder mehrere Phasen
Vorteile	Anforderungen zu Beginn verfügbar Kein umfangreiches Versionsmanagement notwendig Erfahrungen können direkt im Projekt genutzt werden	Gut wenn Anforderungen unklar, instabil oder bei geringen Erfahrungen Korrekturen bzw. Veränderungen jederzeit möglich Sanfter Umstieg für zukünftige Nutzer Geringes Risiko für Fehlentwicklungen Bei Zeitdruck Teilauslieferung möglich	Anforderungen werden vollständig ermittelt und erfüllt Kein Versionsmanagement notwendig, da wenig Versionen Gut bei unklaren Anforderungen Reduziertes Risiko einer Fehlentwicklung	Höhere Akzeptanz durch Anwender durch Partizipation Gut wenn Anforderungen unklar, instabil oder bei geringen Erfahrungen Korrekturen jederzeit möglich Sanfter Umstieg für zukünftige Nutzer Geringes Risiko für Fehlentwicklungen
Nachteile	Ungeeignet bei variierenden Anforderungen Viel Erfahrung notwendig Erst spät sichtbares Ergebnis, Funktionen nicht reduzierbar	Umfangreiches Versions- und Konfigurationsmanagement notwendig Zusammenfügen der einzelnen Elemente / Inkremente evtl. schwierig	Aufwand / Kosten für Umsetzung der Prototypen Prototyp wird zu schnell als Endsystem betrachtet (v. a. vom Anwender)	Umfangreiches Versions- und Konfigurationsmanagement notwendig Erfolg u. a. abhängig von Kompetenz, Motivation und verfügbaren Ressourcen der Anwender

Ein Hauptunterscheidungsmerkmal zwischen sequentiellen Modellen und den weiteren Kategorien ist das sequentielle Vorgehen, ohne komplette Iterationen gesamter Entwicklungsabschnitte in dem Prozess vorzusehen.

Das Wasserfallmodell von Royce (1970), welches ein sequentielles Modell darstellt, beinhaltet einen linearen Ablauf von Entwicklungsphasen. Es entstand zur Entwicklung komplexer Softwaremodelle. Jede Softwareentwicklung sollte folgende wesentliche Schritte enthalten:

- Systemanforderungen (System requirements)
- Softwareanforderungen (Software requirements)
- Analyse (Analysis)
- Programmdesign (Program design)
- Programmieren (Coding)
- Test (Testing)
- Einsatz (Operations)

Diese Elemente werden linear bearbeitet. Iterationen sind nur vorgesehen, falls ein Schritt nicht zufriedenstellend abgeschlossen werden kann und dieses im Folgeschritt erkannt wird. Größere Iterationen sind aber aufgrund des immer fortschreitenden Detaillierungsgrades nicht erwünscht. Eine vollständige und korrekte Beendigung eines Schrittes ist essentiell für den weiteren Prozessablauf, da sich Fehler und somit das Risiko kumuliert und darüber hinaus Designfehler nicht mehr beheben lassen.

Um diese Herausforderungen zu adressieren, gibt es Methoden, das Risiko zu managen und die Komplexität zu beherrschen.

Es ist ein Preliminary-Programm-Design vor dem Schritt der Analyse einzufügen. Hier werden die notwendigen Ressourcen, wie Rechenleistung oder Speicher, festgelegt. Auch wenn an dieser Stelle eine genaue Festlegung aufgrund der noch nicht erfolgten Analyse nicht vollständig sein kann, hilft es aber im Weiteren bei der Analyse der Anforderungen.

Der zweite wesentliche moderierende Schritt ist die Dokumentation des Designs, da die Qualität der Entwicklung von der Dokumentation abhängt. Die Designer müssen mit Programmierern, Management und dem Kunden kommunizieren. Weiterhin repräsentieren zu Beginn des Prozesses die

Dokumentation, die Spezifikation und das Design. Die Qualität der Dokumentation zeigt sich oft erst während des Tests (zur Unterstützung der Testfälle), des Einsatzes (die Software kann auch ohne die Entwickler eingesetzt werden) und des Redesigns (gute Dokumentation erlaubt effektives Redesign, Updates und Retrofitting).

Der dritte moderierende Schritt ist die Wiederholung. Die erste frühe Version stellt eine Simulation des Endproduktes in Form einer kleineren Variante dar. Diese Simulation sollte ca.  $\frac{1}{4}$  der Projektlaufzeit betragen. Dadurch können mögliche auftretende Probleme früh erkannt und im Realdurchlauf frühzeitig beseitigt werden.

Der vierte moderierende Schritt ist die Planung und Überwachung der Testphase. Diese sollte von Testspezialisten ausgeführt werden, was wiederum einer guten Dokumentation bedarf. Viele Fehler können direkt durch eine visuelle Untersuchung des Codes von nicht an der Programmierung beteiligten Personen erkannt werden, wie Vorzeichenfehler oder falsche Sprungadressen. Weiterhin ist ein Test aller Logikpfade notwendig, um alle weiteren Programmierfehler zu entdecken.

Der fünfte moderierende Schritt ist die Einbeziehung des Kunden. Durch die Einbeziehung des Kunden vor der finalen Auslieferung können an den Stellen der Design- und Testphase frühzeitig mögliche verschiedene Interpretationen der Anforderungen adressiert und angepasst werden.

In Abbildung 11 ist der Ablauf der Entwicklungsschritte graphisch dargestellt.

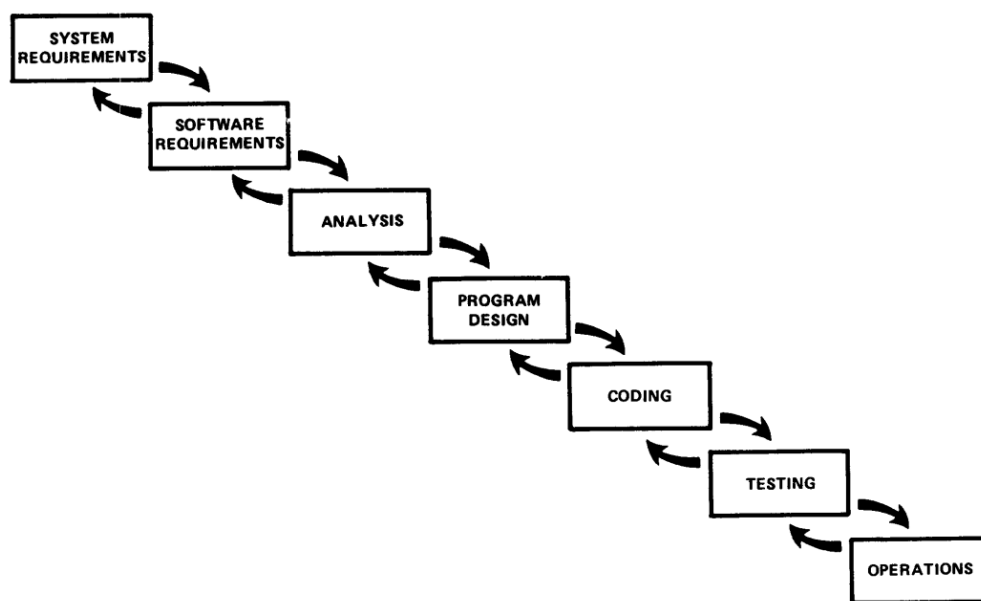


Abbildung 11: Wasserfallmodell nach Royce (1970)

Hier erkennt man den linearen Charakter des Entwicklungsmodells von den Anforderungen, über das Design bis zum Einsatz des entwickelten Systems.

In Abbildung 12 sind darüber hinaus die nach Royce (1970) notwendigen moderierenden Elemente in der Entwicklung mit Hilfe dieses Modells dargestellt.

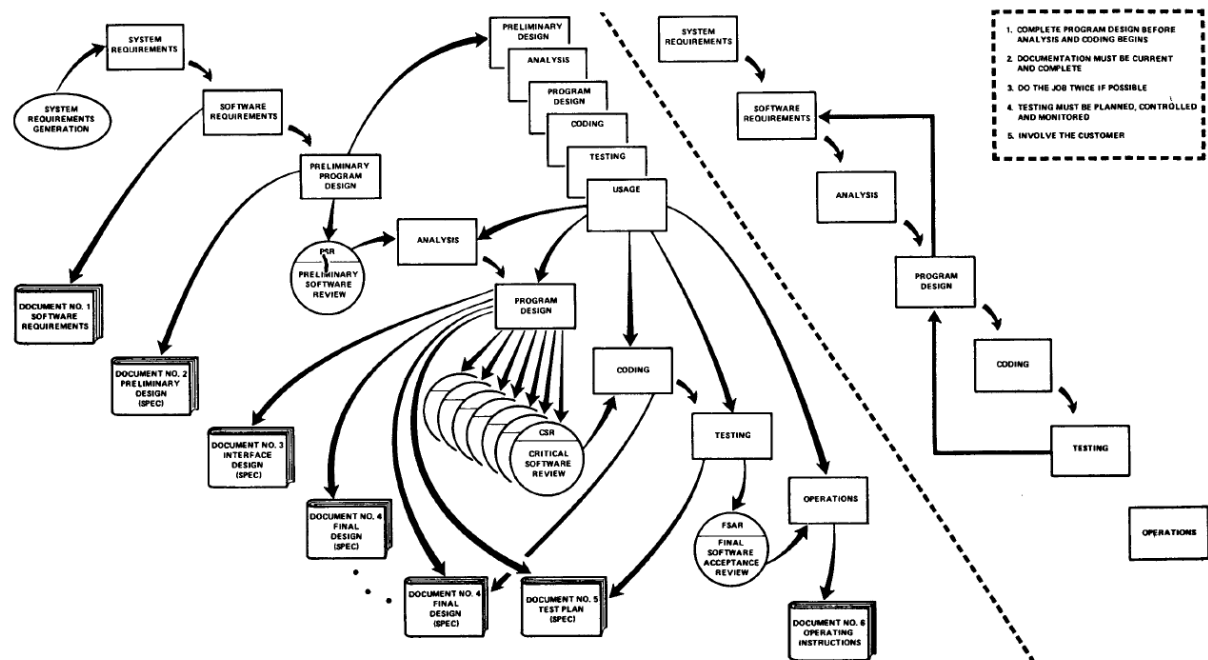


Abbildung 12: Vollständiger Wasserfallprozess nach Royce (1970)

Durch den linearen Ablauf und der in sich abzuschließenden Schritte, ist die Notwendigkeit eines umfangreichen Versionsmanagements gering und die vollständigen Anforderungen sind während jedem Prozessschritt verfügbar. Dazu ist eine genaue Definition der Anforderungen notwendig. Die DIN 69901 beschreibt dabei Methoden des Projektmanagements und definiert wesentliche Elemente der Anforderungsdefinition (DIN 69901). Ein Lastenheft beschreibt die „vom Auftraggeber festgelegte Gesamtheit der Forderungen an die Lieferungen und Leistungen eines Auftragnehmers innerhalb eines Auftrages“ und das Pflichtenheft die „vom Auftragnehmer erarbeiteten Realisierungsvorgaben aufgrund der Umsetzung des vom Auftraggeber vorgegebenen Lastenheftes“. Durch die Erstellung dieser Dokumente können zu Beginn der Entwicklung die Ziele durch die Anforderungsanalyse und die richtige Richtung und Umsetzung der Entwicklung vorgegeben und festgelegt werden.

Nachteilig ist bei dieser Entwicklungsmethodik, dass eine große Erfahrung notwendig ist und sich das Risiko am Ende des Entwicklungsprozesses kumuliert, was zu einer Überschreitung der zeitlichen Anforderung oder der festgelegten Kosten der Entwicklung führen kann.

Iterative und zyklische Modelle sind ebenfalls häufig in der Forschung und Entwicklung anzutreffen. Einer der bekanntesten Vertreter ist das Spiralmodell nach Boehm (1986), in dem folgende Schritte enthalten sind: Festlegung von Zielen, Identifikation von Alternativen und Beschreibung von Rahmenbedingungen, Evaluierung der Alternativen und das Erkennen, Abschätzen und Reduzieren von Risiken, Realisierung und Überprüfung des Zwischenprodukts und Planung des nächsten Zyklus der Projektfortsetzung.

Der nutzerfokussierte Gestaltungsprozess ist in der EN ISO 9241-210 dargestellt. Er enthält die Schritte der Analyse des Nutzungskontextes mit einer Benutzer-, Tätigkeits- und Umfeldanalyse, der Anforderungsdefinition, der Entwicklung eines Prototyps zur Lösungsidee und der Bewertung und Evaluierung.

Die iterativen bzw. zyklischen Modelle bieten gegenüber sequentiellen Modellen den Vorteil, auch bei nicht vollständig klarer Anforderungsdefinition, unter reduziertem Risiko und möglichen, funktionsfähigen Zwischenversionen, eine Entwicklung durchzuführen. Auch die Integration des

---

Nutzers ist oftmals ein zentraler Bestandteil, was die Akzeptanz des Kunden durch Sichtung von funktionierenden Zwischenlösungen und Integrationsmöglichkeiten gewünschter Korrekturen ermöglicht. Jedoch besitzen die Modelle oftmals ein sehr umfangreiches Versionsmanagement, eine notwendige Erstellung (kostenintensiver) Prototypen und einen hohen Aufwand zur Implementierung von Elementen einer Iteration in der Nächsten.

## **2.6. Zwischenfazit und Identifikation der Forschungslücke**

Durch die Eigenschaften von Menschen bei der Fahrzeugführung, die nur begrenzt zur Verfügung stehenden Ressourcen in Verbindung mit der Komplexität der Fahraufgabe, entstehen sehr häufig Situationen, die zu Unfällen oder Beinaheunfällen führen. Fahrerassistenzsysteme sind dabei eine zielführende Art, Fahrer bei der Fahrzeugführung zu unterstützen, ihn in fordernden Situationen zu entlasten und in kritischen Situationen zu warnen und ggf. einzugreifen. Dabei ist eine möglichst frühzeitige Unterstützung anzustreben, um maximalen Sicherheitsgewinn zu erzielen. Der Unterstützungsbedarf des Fahrers ist in komplexen Situationen, wie sie hauptsächlich im städtischen Verkehr auftreten, als hoch zu bewerten, was sich auch durch die hohe Anzahl an Unfällen im städtischen Umfeld darstellt. Automatisierte Systeme zur Fahrzeugführung sind in der Stadt, anders als auf Autobahnen, noch viele Jahre nicht im Serieneinsatz zu erwarten. Somit ist eine Verbesserung vorhandener Assistenzsysteme angebracht. Die Verbesserung vorhandener Assistenzsysteme ist, aus Gründen eines möglichen Warndilemmas im Bereich der Reduktion von Fehlwarnungen bei vergrößertem Zeithorizont von Warnungen, anzustreben. Zur Adressierung dieser Herausforderungen ermöglicht die Einbeziehung des Fahrerzustandes, insbesondere der Fahrerabsicht, in eine Assistenzstrategie, das bislang auftretende Warndilemma zu reduzieren oder sogar gänzlich zu verhindern. Die Führungsebene, mit einem Handlungshorizont von wenigen Sekunden, stellt sich dabei als die effektivste Ebene der Unterstützung dar. Auf der Führungsebene sind die Fahrmanöver mit hohem Querführungsanteil sehr unfallträchtig und es bedarf weiterer Forschung in diesem Feld. Der Fokus in dieser Arbeit liegt auf der Untersuchung und Prädiktion von Fahrerverhalten in Fahrstreifenwechselsituationen, da der Fahrstreifenwechsel ein beispielhaftes Manöver mit hohem Querführungsanteil darstellt. Daten zum Fahrzeugzustand und der Fahrerbeobachtung liefern dabei erfolgsversprechende Merkmale, um Fahrstreifenwechselmanöver präzisieren zu können. Eine Fahrmanöverprädiktion kann einen notwendigen Informationsgewinn erzielen, um Fahrerassistenzsysteme zielgerichtet, unter Vermeidung bzw. Reduktion eines Warndilemmas, verbessern zu können. Bisherige Forschungsarbeiten zeigten weiteren Forschungsbedarf in Bezug auf Nutzung zusätzlicher Daten, Verwendung weiterer Algorithmen oder der Verbesserung der Erkennungsleistung auf. Darüber hinaus basierten einige Arbeiten auf Black-Box Algorithmen, erreichten bei nutzbaren Erkennungsleistungen nur einen geringen zeitlichen Prädiktionshorizont oder fokussierten auf Autobahn und Landstraßen. Um FAS mit dem Ziel der Reduktion eines Warndilemmas im unfallträchtigen Stadtverkehr an den Fahrer anzupassen ist die Entwicklung eines Algorithmus zur Prädiktion von innerstädtischen Fahrstreifenwechseln notwendig.

Zusammenfassend ergeben sich aus den formulierten Zielen (Kapitel 1.2) und dem aktuellen Stand der Forschung folgende Aufgaben, die in dieser Arbeit untersucht werden:

- Auswahl eines geeigneten Prozesses zur Entwicklung eines Algorithmus zur Fahrmanöverprädiktion mit dem Fokus auf inter- und intraindividuelles Fahrerverhalten beim Fahrstreifenwechsel
- Entwicklung eines Algorithmus zur Fahrmanöverprädiktion mit dem Ziel der Fahrstreifenwechselprädiktion im innerstädtischen Verkehr entlang des ausgewählten Prozesses:

- 
- Definition und Bewertung wesentlicher Merkmale des Algorithmus
  - Datensammlung natürlichen Fahrerverhaltens für die Synthese des Algorithmus
  - Auswahl geeigneter Eingangsgrößen für den Algorithmus anhand einer quantitativen Metrik
  - Synthese des Algorithmus unter Nutzung der gesammelten Daten mit dem Ziel einer Fahrmanöverprädiktion
  - Validierung des Algorithmus mit Hilfe eines geeigneten Verfahrens
  - Prototypische Implementierung und Test des Algorithmus in ein Fahrzeug
  - Bewertung und Einordnung der Ergebnisse in den Forschungskontext:
    - Besitzt der Algorithmus das Potential die angestrebten Verbesserungen von Fahrerassistenzsystemen zu erreichen

---

### 3. Methodik der Algorithmenentwicklung

---

Im Kapitel 3 wird die Methodik der Algorithmenentwicklung aufgezeigt. Dabei wird ein passender Entwicklungsprozess aus möglichen Prozessen des Kapitels 2.5 ausgewählt. Im weiteren Verlauf wird die Algorithmenentwicklung entlang des ausgewählten Entwicklungsprozesses dargestellt.

#### 3.1. Auswahl des Entwicklungsprozesses

Als Entwicklungsmodell sind alle aufgeführten Modelle aus Kapitel 2.5 durch mehrfach erfolgreichen Einsatz in bisherigen Arbeiten geeignet. Jedoch bietet sich für diese Arbeit ein **sequentieller Prozess** an, da die vollständigen Anforderungen in jedem Entwicklungsschritt verfügbar sind, die Ergebnisse jedes Entwicklungsschrittes unmittelbar mit den Anforderungen abgeglichen und direkte Aussagen zu einer möglichen Funktion abgeschätzt werden können. Weiterhin soll die Entwicklung eines Algorithmus zur Fahrmanöverprädiktion in dieser Arbeit nicht durch die frühzeitige Festlegung einer Zielfunktion auf einen speziellen Einsatzbereich eingeschränkt werden, sondern erst nach der Evaluierung und Potentialabschätzung mit möglichen Assistenzsystemen verknüpft werden. Daher können keine Zwischenversionen mit den Kunden, in diesem Fall dem adressierten Assistenzsystem, abgeglichen werden ohne die Erstellung aufwändiger Prototypen. Daher werden iterative Modelle für diese Arbeit verworfen und ein sequentielles Modell zur Entwicklung des Algorithmus zur Fahrmanöverprädiktion verwendet.

Diese Arbeit ist an die Vorgehensweise einer sequentiellen Entwicklung angelehnt (Royce 1970), vgl. auch Kapitel 2.5.

#### 3.2. Systemanforderungen

Die Anforderungen an das System ist die Modellierung des Fahrerverhaltens zur Ermöglichung einer **Fahrmanöverprädiktion**. Durch die Modellierung natürlichen Fahrerverhaltens besteht die Chance, eine große Bandbreite an unterschiedlichen inter- und intraindividuellem Fahrerverhalten abzudecken und präzisieren zu können. Eine Erkennung von Fahrmanövern anhand einfacher Merkmale, wie das Überfahren einer Fahrstreifenmarkierung ohne Aktivierung des Blinkers zur Erkennung eines Spurverlassens, ermöglicht es nicht, eine Fahrerwarnung so frühzeitig auszugeben, dass ein Fahrer rechtzeitig eine angemessene Reaktion zeigen kann. Dadurch ist kein Sicherheitsgewinn oder eine Reduktion des Warndilemmas erzielbar. Deshalb ist eine Prädiktion von Fahrerverhalten notwendig und zur Verbesserung aktueller Fahrerassistenz zielführend.

Da es sich bei einer Prädiktion um eine probabilistische Information handelt, soll das System mit Hilfe eines Algorithmus eine **Wahrscheinlichkeit** für die Ausführung eines Fahrmanövers berechnen und ausgeben können. Die Berechnung einer Wahrscheinlichkeit ist wesentlich für adressierte Fahrerassistenzsysteme unterschiedlicher Modalität, da die jeweiligen Systeme entsprechend ihres Charakters informierend, warnend oder eingreifend, abhängig von einer Wahrscheinlichkeit und einer Kritikalität der Situation, aktiviert werden sollten. Eingreifende Systeme sollten beispielsweise nur aktiviert werden, wenn der Fahrer selbstständig eine Situation nicht mehr entschärfen kann und die Wahrscheinlichkeit für das Ausbleiben einer angemessenen Fahrerhandlung sehr hoch ist. Ein Fehleingriff kann nicht nur ein Ärgernis für den Fahrer darstellen, sondern auch ein nicht notwendiger kritischer Eingriff in die Fahrzeugstabilität sein. Das Treffen dieser Entscheidung ist nur mit Hilfe einer binären Information für verschiedene Fahrerassistenzsysteme nicht möglich. Darüber hinaus ist die Berechnung und Abschätzung eines **Zeithorizontes**, zu dem ein vom Fahrer induziertes Fahrmanöver

---

startet, ebenso relevant, da warnende Assistenzsysteme den Fahrer einerseits so frühzeitig warnen sollten, dass dieser auf die vorliegende Situation rechtzeitig und angemessen reagieren kann, jedoch nicht zu früh, um die Entstehung eines möglichen Warndilemmas zu verhindern. Wird eine Warnung zu früh ausgegeben, kann dieses ein Warndilemma hervorrufen, sofern der Fahrer eine Situation vollständig und richtig interpretiert hat und seinen Eingriff zu einem späteren Zeitpunkt plant. Wird eine Warnung zu spät ausgegeben, könnte eine angemessene Fahrerhandlung zu spät ausgeführt werden und der Sicherheitsgewinn schwindet gegenüber Fahrerassistenzsystemen ohne Fahrmanöverprädiktion.

Damit Fahrerassistenzsysteme von der Information zum prädictierten Fahrerverhalten profitieren können, soll die Information kontinuierlich berechnet und ausgegeben werden können, damit diese zeitnah an die adressierten Fahrerassistenzsysteme weitergegeben werden. Daher ist es wesentlich, dass ein Algorithmus zur Fahrmanöverprädiktion **echtzeitfähig** ist. Wird eine Information zur Fahrerabsicht nicht echtzeitfähig an ein Assistenzsystem übermittelt, kann nicht sichergestellt werden, dass die Assistenzfunktion jederzeit ihre volle Wirkung entfalten kann.

Aus diesen Systemanforderungen lassen sich die Anforderungen an die Software, in dieser Arbeit des zu entwickelnden Algorithmus, ableiten.

### 3.3. Softwareanforderungen

Die Software soll gemäß den Systemanforderungen, Fahrmanöver in Echtzeit mit der Angabe von Eintrittswahrscheinlichkeit und Zeithorizont prädictieren. Dazu ist ein geeignetes Berechnungsverfahren, auch Algorithmus genannt, notwendig, welches die Verarbeitung von Eingangsgrößen zu definierten Ausgangsgrößen ausführt. Die gewünschten **Ausgangsgrößen**, Eintrittswahrscheinlichkeit und Zeithorizont, wurden durch die Systemanforderungen bereits definiert. Um die Ausgangsgrößen berechnen zu können, benötigt der Algorithmus **Eingangsgrößen**, die eine Prädiktion von Fahrerverhalten erlauben. Für eine kontinuierliche Berechnung der Ausgangsgrößen ist eine permanente Bereitstellung von Eingangsgrößen notwendig. Dieses ist durch die Sensorik und Vernetzung über Bus-Systeme in modernen Fahrzeugen gewährleistet. Darüber hinaus müssen die Eingangssignale Informationen über ein zukünftiges Fahrerverhalten beinhalten, damit eine Prädiktion möglich ist. Einige Arbeiten haben bereits erfolgreich Fahrmanöverprädiktionen unter Nutzung von **Fahrzeug- und Fahrerbeobachtungsdaten** aufgezeigt. Daraus kann man ableiten, dass diese Signale die notwendigen Informationen beinhalten. Es besteht die Möglichkeit alle möglichen Signale, die messbar sind, zu verwenden, da diese in der Summe den maximalen Informationsgehalt besitzen. Allerdings würden eine sehr hohe Anzahl und Frequenz von Signalen, die Echtzeitfähigkeit des Algorithmus verwehren, da mit Blick auf eine spätere Implementierbarkeit in ein reales Fahrzeug, nur begrenzte Rechen- und Speicherkapazität auf der Zielhardware zur Verfügung stehen. Da die Erkennungsgenauigkeit und Recheneffizienz eines Algorithmus unter anderem von der Anzahl und Komplexität der Eingangsgrößen abhängt, ist eine zielgerichtete Auswahl der Eingangsgrößen aus allen zur Verfügung stehenden möglichen Signalen notwendig.

Die Theorie von Occam (Occam's Razor) beschreibt weiterhin, dass nur eine begrenzte Anzahl an Merkmalen ein allgemeingültiges Modellverhalten darstelle und eine zu hohe Anzahl die Fähigkeit zur Generalisierung reduziere (Domingos 1999). Daher ist eine Auswahl der geeignetsten Signale notwendig. Dieses erfolgt zuerst durch eine Analyse bestehender Arbeiten (Kapitel 2.3). Dabei hat sich eine Vielzahl an Signalen für eine Fahrmanöverprädiktion als geeignet herausgestellt. Eine weitere Reduktion dieser Anzahl wäre mit dem Ziel eines allgemeingültigen Modells wünschenswert. Dazu bietet es sich an einen **Bewertungsmaßstab** zu besitzen, welcher verschiedene Signale miteinander vergleichend betrachtet und eine quantitative Eignung als Prädiktor für eine Fahrmanöverprädiktion abschätzt. Eine Auswahl der geeigneten Signale durch die direkte Nutzung der Algorithmen zum

---

Vergleich der Performance mit unterschiedlichen Eingangsgrößen ist nicht empfehlenswert, da komplexe Algorithmen oftmals eine hohe Trainingszeit benötigen und eine vollständige heuristische Suche daher nicht effektiv möglich ist. Durch die Generierung eines geeigneten Bewertungsmaßstabs kann gezielt eine Auswahl der geeigneten Eingangsgrößen durchgeführt werden. Dieser Maßstab sollte eine quantitative Bewertung der Signale erlauben und dabei potentielle Erkennungsraten und einen möglichen Zeithorizont der Merkmale berücksichtigen. Die Entwicklung und Nutzung eines Bewertungsmaßstabs wird im Kapitel 4.4 dargestellt.

Nach der Definition der Ausgangsgrößen und einer Auswahl der Eingangsgrößen ist die Auswahl eines geeigneten **Algorithmus** zur Berechnung der erwünschten Ausgangsgrößen aus den verwendeten Eingangsgrößen der nächste logische Schritt. Dieser Algorithmus muss dabei mit der Art und Eigenschaft der verwendeten Eingangssignale umgehen können. Verschiedenste Algorithmen wurden bisher zur Fahrmanöverprädiktion eingesetzt. Eine vergleichende Bewertung der Leistungsfähigkeit unterschiedlicher Algorithmen ist gemäß dem No-free-lunch Theorem (Wolpert und Macready 1996) nur unter Verwendung identischer Daten sinnvoll. Die Aufstellung aller funktionierenden Algorithmen und Auswahl des geeignetsten ist sehr aufwändig und würde den Umfang dieser Arbeit überschreiten. Weiterhin besitzen alle bis dahin verwendeten Algorithmen spezifische Vor- und Nachteile. Darüber hinaus ist die Leistungsfähigkeit, gemäß der Analyse und Bewertung der Autoren, überwiegend verbesserungswürdig. Daher wird aufgrund der getroffenen Analyse des Anforderungsprofils und der genannten Vor- und Nachteile der einzelnen Algorithmuskonzepte im Kapitel 2.4 eine theoretische Herleitung eines geeigneten Algorithmus durchgeführt, um auf dieser Basis einen geeigneten Algorithmus zu entwickeln.

Der Algorithmus zur Fahrmanöverprädiktion soll aus ausgewählten Eingangsgrößen das anstehende Fahrmanöver (hier Fahrstreifenwechsel) erkennen und präzisieren. Dazu muss er das bevorstehende Fahrmanöver **klassifizieren**. Weiterhin soll er diese Information durch eine **probabilistische Wahrscheinlichkeitsabschätzung** erweitern. Darüber hinaus soll der Algorithmus einen Prädiktionshorizont ausgeben, um für angeschlossene FAS den richtigen Zeitpunkt für eine Fahrerinformation bestimmen zu können (**Regression**).

Der Algorithmus sollte **modular** bezüglich der **Eingangsgrößen** aufgebaut sein, damit bei neuen Erkenntnissen weitere Eingangssignale hinzugefügt oder ausgetauscht werden können, um die Leistungsfähigkeit weiter zu steigern.

Eine wichtige Voraussetzung für den Algorithmus ist eine **echtzeitfähige** Laufzeit auf einer entsprechenden realen Zielhardware. Während der Entwicklung ist dieser Umstand nicht direkt im Fokus, da eine Optimierung und Anpassung an spezielle Hardware die Rechenzeit in gewissen Dimensionen verringern kann, sofern diese in einer angemessenen Größenordnung in Relation zum aktuellen Stand der Technik liegt. Echtzeitfähigkeit definiert sich dabei durch die Festlegung einer Zeitspanne, in der unter allen Umständen ein vollständiger Berechnungsdurchlauf absolviert werden kann. Diese Zeitspanne sollte so gering gewählt werden, dass angeschlossenen Fahrerassistenzsystemen rechtzeitig und in einer ausreichenden Häufigkeit eine Fahrerinformation zum prädictierten Fahrerverhalten zur Verfügung gestellt werden kann, um die Systemaktion an das prädictierte Fahrerverhalten zu adaptieren. Eine zu hohe Frequenz würde bei der Wahl eines komplexen Algorithmus jedoch die Echtzeitfähigkeit gefährden. Darüber hinaus ist eine übertriebene Häufigkeit nicht zielführend, da die Informationen, welche dem Fahrer zur Verfügung gestellt werden, ihn zu einer Handlung motivieren sollen. Der Reaktionszeitraum, der dem Fahrer dabei eingeräumt werden sollte, beträgt im Stadtverkehr ca. zwei bis drei Sekunden (Naujoks et al. 2012). Da eine Reaktionszeit von 100ms selbst in geübten Handlungen nicht unterschritten werden kann, ist eine zielführende Festlegung der Abschluss eines vollständigen Berechnungsdurchlaufs innerhalb von 100ms.



---

Der Algorithmus sollte ein **white-box** Algorithmus sein, damit der Zustand und das Verfahren der Berechnung jederzeit nachvollziehbar und analysierbar sind. Black-box Algorithmen bieten diese Möglichkeit nicht. Zum einen ermöglicht diese Festlegung die Analyse und Extraktion des gewonnenen Wissens für weitere Forschung und vereinfacht zum anderen eine Absicherung nach der ISO Norm Road Vehicles – Functional Safety (ISO 26262), welche bei einer zukünftigen Implementierung in ein für den Straßenverkehr zugelassenes Fahrzeug benötigt wird.

Weiterhin soll der Algorithmus **natürliches Fahrerverhalten** verarbeiten können. Daher wird dieser mit **inter- und intraindividuell** verschiedenen Merkmalen konfrontiert, da natürliches Fahrerverhalten durch diese Eigenschaft geprägt ist. Dazu sollte der Algorithmus diese **Unschärfe und Unsicherheit** aktiv adressieren, um diese zielgerichtet verarbeiten zu können und nicht ausschließlich durch Robustheit der Berechnung kompensieren. Ein Algorithmus, welcher einen Fahrstreifenwechsel durch das Überschreiten eines diskreten Wertes für den Lenkwinkel erkennt, kompensiert die individuellen Verschiedenheiten nur durch die Wahl eines geeignet hohen Wertes (Robustheit), um wenig Fehlerkennungen zu produzieren. Ein geeigneter Algorithmus modelliert im Unterschied dazu, diese individuellen Unterschiede in einer Manöverausführung und berücksichtigt diese bei der Berechnung der Eintrittswahrscheinlichkeit.

Durch das Auftreten verschiedener Merkmale zu unterschiedlichen Zeitpunkten, vor und während der Manöverausführung, sollte der Algorithmus ebenso mit dieser Art von Daten umgehen können. Diese Daten, auch **Zeitreihen** oder **time-series data** genannt, besitzen die Eigenschaft, nicht nur singular zu einem Zeitpunkt betrachtet werden zu können, sondern sollten durch den vorhandenen Zusammenhang über mehrere aufeinanderfolgende Elemente verarbeitet werden. Darüber hinaus treten bei einer natürlichen Fahrzeugführung einzelne Merkmale nicht immer in derselben Reihenfolge oder im selben kausalen Zusammenhang zueinander auf. Beispielsweise wird nicht bei jedem Fahrstreifenwechsel der Fahrtrichtungsanzeiger zur Ankündigung dieses Fahrmanövers aktiviert. Dieses ist ebenso, wie eine zeitliche Varianz, in den Daten zu berücksichtigen.

### 3.4. Analyse

Nach der Definition der System- und Softwareanforderungen folgt der Entwicklungsschritt der Analyse. Hierbei werden die relevanten Herausforderungen analysiert und eine mögliche Umsetzbarkeit entwickelt. Für die Prädiktion von Fahrmanövern ist dabei eine detaillierte Analyse von Fahrerverhalten und Abbildung dessen notwendig. Dieses ist zusammenfassend eine Modellierung des Fahrers und seines Verhaltens.

Es gibt zwei mögliche Herangehensweisen für die Fahrermodellierung. Die Deduktion (**top-down** Methoden) und die Induktion (**bottom-up** Methoden) (vgl. auch Kapitel 1.2). Top-down Methoden eignen sich zur allgemeinen Beschreibung von Fahrerverhalten und sind u.a. in der Arbeit von Langer (2016) zu finden. Bottom-up Methoden eignen sich für die Entwicklung von Anwendungsfällen, bei denen die Zielszenarien bekannt sind. Die Methode der Induktion ist für das zu erreichende Ziel eines echtzeitfähigen Algorithmus zur Fahrmanöverprädiktion zielführend, da die bisherige Forschung die Eignung aufgezeigt hat und deduktive Ansätze u.a. durch ihre hohe Komplexität weniger geeignet erscheinen. Daher wird in dieser Arbeit ein induktiver Ansatz weiter verfolgt.

Die Entwicklung von Algorithmen nach der bottom-up Methodik analysieren Daten einer oder mehrerer Beobachtungen und synthetisieren daraus die zutreffenden Berechnungsvorschriften, welche diese Beobachtungen erklären. Für eine automatisierte Analyse von Daten eignen sich Methoden des **Maschinennlernens** (machine learning). Hierbei werden spezifische Muster durch einen Computer analysiert und bei **überwachten** (supervised) Lernverfahren gemäß entsprechender

---

Kontextinformationen bewertet. **Unüberwachte** (unsupervised) Lernverfahren suchen ohne die Nutzung von Kontextinformationen explorativ Zusammenhänge in den Daten, somit ist die Integration von Vorwissen nicht direkt möglich.

In dieser Arbeit wird auf die Verwendung eines überwachten Maschinenlernens gesetzt, da nicht explorativ nach unbekannten Zusammenhängen gesucht werden soll, sondern gezielt Vorgänge und Fahrerhandlungen bei definierten Manöverausführungen für die Entwicklung eines Algorithmus benutzt werden. Die gelernten Muster können dann in weiteren Schritten auf bis dahin unbekannte Daten angewendet werden, um eine Klassifizierung dieser unbekannten Daten anhand der gelernten Informationen vorzunehmen.

Für die Nutzung von Maschinenlernverfahren ist eine Datenbasis notwendige Voraussetzung. Da ein Ziel der Entwicklung die Repräsentation **natürlichen Fahrerhaltens** ist, sollen die zugrunde liegenden Daten dieses beinhalten. Dazu eignen sich **Probandenstudien** mit Datenaufzeichnung zur späteren Analyse (Bruder et al. 2007), da diese es ermöglichen, das gewünschte menschliche Verhalten bei der Fahrzeugführung zu erzielen.

Dabei gibt es verschiedene **Versuchsumgebungen**, um die notwendigen Daten zu sammeln (Bruder et al. 2007). Fahrversuche in simulierter Umgebung ermöglichen es, dabei zukunftssträchtige Technologien zu realisieren oder für die Probanden gefährliche Situationen zu erstellen. Nachteilig ist jedoch das unnatürliche Fahrerverhalten, welches häufig durch die Probanden bei Simulatorstudien gezeigt wird. Feldtestversuche zeichnen sich durch eine sehr hohe Realität aus, allerdings kann es vorkommen, dass gewünschte Situationen nicht oder nur in geringem Umfang auftreten, so dass das Verhältnis zwischen Nutzdaten und der Gesamtdatenmenge nicht sehr effizient ist, was den Aufwand der Studie und der Analyse stark ansteigen lässt. Ein Kompromiss zwischen beiden Varianten ist die Durchführung von **kontrollierten Studien**. Eine kontrollierte Studie im Realverkehr konfrontiert die Probanden mit realem Straßenverkehr und erzeugt somit sehr realistisches Fahrerverhalten. Dabei lassen sich die Umgebungsbedingungen, wie der Umfeldverkehr, nur sehr begrenzt moderieren, wodurch das jeweilige Fahrerverhalten immer im Kontext mit der vorliegenden Umgebung betrachtet werden muss und somit eine detaillierte Analyse erschwert. Eine Kontrolle dieser Umgebungssituationen ist bei Fahrversuchen im kontrollierten Feld möglich. Hieraus resultiert in den definierten Situationen Fahrerverhalten der Probanden, welches untereinander sehr gut vergleichbar ist. Dabei eignen sich insbesondere Versuche im kontrollierten Feld, vor allem zur realistischen Darstellung von reproduzierbaren und auch kritischen Situationen (vgl. auch Bruder et al. 2007). Die Eignung einer kontrollierten Feldstudie zur Generierung realistischer Fahrerhaltensdaten mit dem Fokus auf das inter- und intraindividuelle Fahrerverhalten ist sehr hoch. Da das Fahrerverhalten starken inter- und intraindividuellen Schwankungen bei der Manöverausführung unterliegt, ist eine kontrollierte Untersuchung des Fahrerhaltens zur Entwicklung eines Algorithmus zur Fahrmanöverprädiktion angemessen. Eine geeignete Probandenstudie konfrontiert die Fahrer mit Situationen, in denen sie möglichst natürliches Verhalten zeigen sollen, um realistisches Fahrerverhalten aufzeichnen zu können und eine mögliche Übertragbarkeit auf das Verhalten im realen Straßenverkehr vorliegt. Eine geeignete Probandenstudie zeichnet sich darüber hinaus dadurch aus, dass die dargestellten Situationen, in denen Daten aufgezeichnet werden, nicht nur die zu untersuchenden Fahrmanöver enthält, sondern eine allgemeine Repräsentation von typischen Verkehrssituationen mit unterschiedlichsten Fahrmanövern darstellt. Dadurch werden Daten generiert, welche es ermöglichen, die Leistungsfähigkeit eines Algorithmus auf Fahrmanöverprädiktion nicht nur im positiven Fall der korrekten Erkennung von gewünschten Fahrmanövern zu testen, sondern auch die richtige Nichterkennung des Fahrmanövers in möglichst allen anderen Situationen zu erreichen, um eine mögliche Fehlauflösung von FAS zu verhindern.

Die **Probandenstudie** sollte alle notwendigen Elemente zur Vollständigkeit enthalten, aber auf die wesentlichen Elemente aus Gründen der Sparsamkeit reduziert sein. Enthalten die Daten möglichst

---

natürliches Fahrerverhalten in nahezu allen notwendigen Situationen, dann sind die Daten für die Entwicklung eines Algorithmus geeignet. Grundsätzlich sollten die Probanden im Rahmen der Studie alle verfügbaren **Fahrmanöver** ausführen. Dieses bietet den Vorteil, selbst wenn nur eine begrenzte Anzahl von Fahrmanövern detailliert analysiert und prädictiert werden soll, mit Hilfe der Daten aller möglichen Fahrmanöver, spezifische Merkmale für ein gewisses Manöver zu extrahieren, ohne dabei Merkmale, welche in allen Fahrmanövern auftreten, zu berücksichtigen. Werden nur einige Fahrmanöver betrachtet, so können die gefundenen spezifischen Merkmale ebenfalls bei den nicht untersuchten Manövern auftreten und somit die Differenzierbarkeit zwischen diesen Manövern bei der Erkennung und Prädiktion verringern.

Ein geeigneter Katalog von Fahrmanövern unterstützt dabei das Design der Studie. Er sollte dabei vollständig sein, eine einheitliche Definition der Manöver erlauben, aber auch im Umfang sparsam gestaltet sein, um ein effizientes Handling zu ermöglichen. Einige Fahrmanöverkataloge bestehen aus einer immensen Anzahl von Fahrmanövern in jeglicher Kombination von Manöverausführungen, Straßenverhältnissen oder Wetter. Andere Manöverkataloge sind nicht vollständig, da diese beispielsweise Notmanöver zur Unfallvermeidung aussparen (Nagel und Enkelmann 1991; Tölle 1996). Der Fahrmanöverkatalog von Dambier (2010) ist ein vollständiger Fahrmanöverkatalog, bestehend aus insgesamt 12 Fahrmanövern, welcher alle Bedingungen an einen geeigneten Katalog erfüllt. Daher wird in dieser Arbeit auf den Manöverkatalog von Dambier (2010) zurückgegriffen, da dieser alle relevanten Fahrmanöver beinhaltet, aber auch das Sparsamkeitsprinzip erfüllt.

Die Entwicklung eines Algorithmus zur Fahrmanöverprädiktion soll zur Erhöhung der aktiven Sicherheit beitragen, daher werden für das Studiendesign die Fahrmanöver, in denen eine Gefährlichkeit sehr gering ist, ausgenommen. Dieses beinhaltet die Manöver des Stillstands und Parkens. Mit dem Fokus dieser Arbeit wird auch das Manöver des langsamen Navigierens ausgeschlossen, um die Ablenkung der Probanden möglichst konstant gering zu halten. Würde das Element der Ablenkung oder Müdigkeit der Probanden nicht moderiert werden, so würden sich erhebliche Einflüsse auf das Verhalten ergeben, was eine fokussierte Untersuchung von Fahrerverhalten stark beeinträchtigt. Der nächste Schritt des Studiendesigns ist die Wahl der Umgebung. Das Fahren auf der Autobahn ist einerseits bereits vielfach untersucht und darüber hinaus werden Systeme zur automatisierten Fahrzeugführung zeitnah Einzug in Serienfahrzeuge erhalten. Daher ist eine Untersuchung mit dem Ziel der Verbesserung warnender Fahrerassistenzsysteme in diesem Umfeld nicht zeitgemäß. Da der **Stadtverkehr** durch die große Heterogenität der Situationen und der daraus resultierenden möglichen Ablenkungen eine hohe Anzahl potentieller Unfallgefahren beinhaltet und Serienanwendungen zum automatisierten Fahren aus denselben Gründen noch einige Zeit auf sich warten lassen, sind Versuche in und für dieses Umfeld am zweckmäßigsten. Fahrmanöver mit lateralem Führungsanteil stellen diejenigen Manöver dar, in denen häufig Unfälle passieren und somit eine Unterstützung des Fahrers zielgerichtet erscheint (vgl. Kapitel 1.2). Eine vollumfängliche Analyse und Bewertung aller möglichen Fahrmanöver in allen erdenklichen Situationen würde den Umfang dieser Arbeit deutlich überschreiten, daher fokussiert diese Arbeit auf einen ausgewählten repräsentativen Bereich, dem Fahrmanöver des Fahrstreifenwechsels (vgl. Kapitel 2.4). Weitere Details zur Probandenstudie können Kapitel 4.1 entnommen werden.

Zum Studiendesign gehört auch die Auswahl der **aufzuzeichnenden Signale** und eingesetzten Messmethoden. Kopf (2005) beschreibt, dass zwischen dem Blickverhalten, der Kopfbewegung, dem Bedienverhalten und den Umgebungsinformationen eine gesicherte Korrelation zur Fahrerintention existiert. Weitere Merkmale, wie Lidschlag oder Herzfrequenz, weisen keine Anzeichen für anstehende Fahrmanöver auf und haben somit geringe Aussicht als wirksame Merkmale zur Fahrmanöverprädiktion genutzt zu werden, weshalb sie im Rahmen dieser Studie nicht weiter untersucht werden. **Fahrzeugdaten** können in modernen Fahrzeugen durch die Aufzeichnung des Datenverkehrs des Fahrzeugbussystems mit relativ geringem Aufwand aufgezeichnet werden. Weiterhin verspricht

---

**Fahrerbeobachtung**, also die Analyse des Blickverhaltens und der Kopfbewegung, frühe Informationen zur Prädiktion von Fahrmanövern zu liefern. Daten zur Fahrerbeobachtung bieten die Möglichkeit, die Phase der Informationsaufnahme des Fahrers auszuwerten und somit auf mögliches zukünftiges Verhalten zu schließen. Deshalb ist eine vergleichende Betrachtung mit Fahrzeugdaten sinnvoll und für eine zukünftige Implementierung in einen Algorithmus zur Fahrerintentionserkennung anstrengenswert. Intrusive Fahrerbeobachtungsverfahren schränken Fahrer in ihrer Bewegungsfreiheit ein und verfälschen somit möglicherweise das natürliche Bewegungsverhalten der Probanden, weshalb nicht intrusive Methoden zur Fahrerbeobachtung vorzuziehen sind. Optische Eyetrackingsysteme auf Basis von Fahrerbeobachtungskameras analysieren das Fahrerblick- und Kopfbewegungsverhalten und liefern alle notwendigen Signale, die für eine Analyse des Fahrerverhaltens mit dem Ziel der Fahrmanöverprädiktion notwendig sind. Daher wird in dieser Arbeit ein berührungsloses System zur Fahrerbeobachtung eingesetzt.

Die gewonnenen **Daten** müssen in folgenden Schritten für die Nutzung **aufbereitet und analysiert** werden, um sie zur Synthese eines Algorithmus zur Fahrmanöverprädiktion nutzen zu können. Die Aufbereitung ist insbesondere bei der Verwendung von überwachten Maschinenlernverfahren notwendig, da die Daten in spezieller Weise aufbereitet und markiert sein müssen, um dem verwendeten Verfahren wichtige Kontextinformationen zu den Daten bereitzustellen. Diese sogenannten **Flags** oder **Labels** setzen ein Zeichen, an welcher Stelle in den Daten ein Proband ein definiertes Fahrmanöver ausgeführt hat. Dabei soll eine Markierung einheitlich für ein Fahrmanöver definiert sein, um eine automatische Verarbeitung und ein Vergleich der Daten zu ermöglichen. Eine Markierung, vgl. Chovan et al. (1994), in der ein Fahrstreifenwechsel mit der Informationsbeschaffungs-Phase (information gathering) beginnt, ist stark abhängig vom jeweiligen Verhalten des Fahrers in der speziellen Situation. Diese Definition ist somit nicht für alle Fahrer und Situationen einheitlich und die Festlegung, ab wann diese Phase beginnt, ist sehr subjektiv. Es ist in diesem Fall schwer zu differenzieren, welche Blicke zur Informationsgewinnung für den anstehenden Fahrstreifenwechsel gelten und welche zur Informationsgewinnung eines Freiraums beim Geradeausfahren gehören.

Bei dem Beispiel Fahrstreifenwechsel wäre die Markierung des Zeitpunktes, bei dem das jeweilige Vorderrad die Fahrstreifenmarkierung berührt, zielführender. Dieses ist zum Zeitpunkt  $TLC = 0s$  der Fall. Die Verwendung der TLC ist in diesem Fall günstig, da sie einen, über alle Probanden einheitlichen Zeitpunkt bei der Ausführung eines Fahrstreifenwechsels beschreibt. Weiterhin bezeichnet dieser Zeitpunkt den Beginn des Eindringens des eigenen Fahrzeuges in den Nachbarfahrstreifen. Ab diesem Zeitpunkt kann das eigene Fahrzeug eine Gefahr für Fahrzeuge auf dem Nachbarfahrstreifen darstellen. Somit ist dieser Wert auch als Referenz für die Bewertung einer zeitlichen Prädiktion für eine Warnung geeignet, da ab diesem Zeitpunkt das Fahrzeug potentiell einer Unfallgefahr ausgesetzt ist und ein Fahrer bis spätestens zu diesem Zeitpunkt eine Korrekturhandlung eingeleitet haben sollte.

Durch die Markierung der Fahrmanöver in den Daten der Probandenstudie kann ein Verfahren zur Vorauswahl der geeignetsten Signale mit Hilfe eines **Bewertungsmaßstabs** durchgeführt werden, um eine reduzierte Menge an geeigneten Eingangssignalen zu erhalten, welche als Eingangsgrößen dem Algorithmus zur Verfügung gestellt werden.

Wünschenswert sind Prädiktoren, welche spezifisch für das jeweilige Fahrmanöver sind, also möglichst immer in der Vorbereitung oder Ausführung des Fahrmanövers auftreten und im Idealfall bei der Ausführung aller anderen Fahrmanöver nicht vorliegen. Weiterhin ist ein identisches Auftreten, zum Beispiel die Höhe einer Amplitude, wünschenswert. Treten diese Merkmale dann sehr früh vor der Manöverausführung auf, stellen diese Merkmale einen idealen Prädiktor für das jeweilige Fahrmanöver dar. Diese Forderung kann nicht für alle geeigneten Prädiktoren eingehalten werden, da sehr verlässliche Prädiktoren häufig sehr spät vor der Manöverausführung messbar sind, wie das Überfahren der Fahrstreifenmarkierung bei einem Fahrstreifenwechsel. Andere Prädiktoren, welche sehr früh ein

---

Fahrmanöver ankündigen, wie das Setzen des Blinkers oder Kopfrotation zu einem Schulterblick, besitzen das Potential, ein Fahrmanöver frühzeitig erkennen zu können, aber durch das Ausbleiben des Merkmals bei einigen Fahrstreifenwechsel sind diese Prädiktoren nicht alleine geeignet, eine Manöverprädiktion zu berechnen. Da die verschiedenen Algorithmen und Methoden unterschiedlich auf die Spezifität der Prädiktoren reagieren, soll der Fokus auf validen Prädiktoren liegen.

Hierfür eignen sich mehrere Verfahren. Ein sehr einfaches, jedoch effektives Mittel, ist der Einsatz von Entscheidungsstümpfen. Entscheidungsstümpfe sind eine Sonderform von Entscheidungsbäumen mit nur einer Verzweigung. Das Training der Entscheidungsstümpfe ist identisch zu dem Training von Entscheidungsbäumen. Mit Hilfe eines Entscheidungskriteriums wird eine informatorisch ideale Entscheidungsschwelle innerhalb eines Signalverlaufes festgelegt, anhand welcher eine binäre Entscheidung getroffen werden kann, ob ein markiertes Ereignis eintritt oder nicht. Dieses Verfahren ist sehr einfach und für eine hohe Anzahl von Signalen schnell ausführbar. Für eine detaillierte Analyse weniger Signale wäre jedoch ein genaueres Verfahren wünschenswert. Dieses Verfahren sollte nicht nur eine Abschätzung von Richtig- und Fehlerkennungen liefern, sondern eine detaillierte Bewertung unter Berücksichtigung eines Zeithorizontes sowie der Berücksichtigung von Richtig-, Falsch- und Nichterkennungsraten ermöglichen. Somit kann für jedes Signal detailliert eine quantitative Eignung zur Prädiktion eines Fahrmanövers berechnet werden und ermöglicht dadurch eine Auswahl von Eingangssignalen zur Fahrmanöverprädiktion.

### **Bewertungsmaßstab**

Um aus allen möglichen Signalen die geeignetsten auszuwählen, soll auf eine fundierte Methodik zur Auswahl zurückgegriffen werden. Die verwendete Methode ist, einen Bewertungsmaßstab zu entwickeln und zu verwenden, der es ermöglicht, alle Prädiktoren miteinander zu vergleichen und eine Reihenfolge festlegen zu können. Sie gestattet eine Reihung der Prädiktoren entsprechend ihrer erwarteten Eignung zur Fahrmanöverprädiktion für ein spezifisches Manöver und ermöglicht die Auswahl der geeignetsten als Eingangsgrößen für den Algorithmus.

Aus dieser Reihung kann dann im nachfolgenden Schritt die gewünschte Anzahl an Prädiktoren, abhängig von der Komplexität des Algorithmus, ausgewählt werden.

Ein Bewertungsfaktor  $a$  soll für den Anwendungsfall der Fahrmanöverprädiktion folgende Merkmale berücksichtigen: Richtigerkennung, Falscherkennung, Nichterkennung, Zeithorizont:

$$a = f(T, R, F, N)$$

### **Zeithorizont**

Zur Fahrmanöverprädiktion ist es von Bedeutung zu wissen, zusätzlich zur Information ob und mit welcher Wahrscheinlichkeit ein Manöver eintritt, wann eine Manöverausführung beginnt. Daher ist der Zeithorizont ein wichtiger Aspekt, der zur Bewertung von Prädiktoren zur Fahrmanöverprädiktion herangezogen werden soll. Ein Merkmal, welches ein bestimmtes Manöver erst nach der Ausführung erkennt, ist für einige Anwendungen sinnvoll, jedoch für eine Manöverprädiktion ist es ebenfalls wichtig, dass die Merkmale möglichst früh vor einem Manöver auftreten. Zur Berechnung des zeitlichen Vorhersagehorizontes soll ein statistisches Verfahren eingesetzt werden, welches aus den Fahrversuchsdaten die notwendigen Informationen lernt.

### **Robustheit**

Ein Beispiel dafür ist das übliche Folgefahrverhalten im Fahrstreifen beim Geradeausfahren. Hierbei treten kleine Lenkkorrekturen des Fahrers auf, um das Fahrzeug im Fahrstreifen zu stabilisieren. Das

---

Verfahren soll robust gegen diese Ausschläge sein, um die Fehlerkennungsrate, also das fälschliche Erkennen eines Fahrstreifenwechsels bei der Geradeausfahrt, zu reduzieren.

Zur Vorauswahl der geeigneten Prädiktoren wird auf ein Verfahren mit Entscheidungstümpfen zurückgegriffen (Kapitel 4.3). Für eine detailliertere Betrachtung wird im Kapitel 4.4 ein geeigneter Bewertungsmaßstab hergeleitet und angewendet (vgl. auch Heine, Krämer et al. 2015).

### 3.5. Programmdesign

Nach der Analyse der Anforderungen ist der nächste Entwicklungsschritt das Programmdesign. In diesem Abschnitt wird der Aufbau des Algorithmus entsprechend der vorher definierten Anforderungen festgelegt.

Der Algorithmus soll natürliches Fahrerverhalten zur Fahrmanöverprädiktion repräsentieren. Dieses soll er aus den Daten einer Probandenstudie lernen und abspeichern, um es in weiteren Schritten mit Fahrerverhalten in Echtzeit für eine Fahrmanöverprädiktion vergleichen zu können.

Wie im Kapitel 2.4 erläutert, wurde Fuzzy Logik zur Repräsentation **natürlichen menschlichen Verhaltens** entwickelt und ist daher hochgradig für dieses Anwendungsgebiet geeignet. Fuzzy Logik stellt die vielversprechendste Variante zur Modellierung von menschlichem Verhalten dar, da es den Umgang mit **Unschärfe** erlaubt und somit menschliches Verständnis und Handlungen repräsentativ abbilden kann. Fuzzy Logik besitzt aber Schwächen im Umgang mit Daten, welchen zeitliche Zusammenhänge zugrunde liegen. Klassische Fuzzy Logik berechnet aus einem Eingangsdatenvektor direkt die Ausgangsgrößen ohne Berücksichtigung vergangener Informationen. Das Fahrerverhalten vor und während der Fahrmanöverausrührung besitzt zeitliche Eigenschaften, so dass dieser Umstand berücksichtigt werden muss. Daher ist die Theorie der Fuzzy Logik mit Hilfe weiterer Methoden an den Anwendungskontext anzupassen, um einen funktionierenden Algorithmus mit der notwendigen Leistungsfähigkeit zu entwickeln. Eine Erweiterung auf rekurrente Fuzzy Logik vergrößert die Komplexität um ein Vielfaches und gefährdet somit die Anforderung der Echtzeitfähigkeit. Durch die Modellierung der Fuzzy Regelbasis als Zustandsautomat (Bauer 2011), kann eine Aktivierung verschiedener Fuzzy-Regeln über einen **zeitlichen Ablauf** beschrieben werden, ohne einen überproportionalen Anstieg der Komplexität zu erreichen.

Durch eine hohe Inter- und Intraindividualität beim Fahrerverhalten ist eine Repräsentation durch einen Zustandsautomaten jedoch nicht ideal. Um diese Eigenschaften zu berücksichtigen, ist eine Erweiterung des Zustandsautomaten notwendig. Die Interpretation von aktivierten Fuzzy-Regeln als Zustand wird dabei weiterentwickelt. Darüber hinaus soll aber jedes ausgeführte Fahrmanöver als individuelles Verhalten betrachtet und berücksichtigt werden. Eine sequentielle Verknüpfung der aktivierten Fuzzy-Regeln einer Fahrmanöverausrührung führt dabei zu einer **Merkmalssequenz**, welche das jeweilige Fahrerverhalten über den Zeitraum der Sequenzlänge hinreichend genau beschreibt. Diese Sequenz wird als Grundlage des Fahrerverhaltens abgespeichert. Durch eine hohe Anzahl an Daten können somit viele Sequenzen verschiedener Fahrer aufgebaut und abgespeichert werden. Ist die Auswahl der zugrunde liegenden Daten repräsentativ für das Fahrerverhalten einer ausgesuchten Vergleichsmenge von Fahrern, so beinhalten die Sequenzen die gesamte Bandbreite an zu erwartendem Fahrerverhalten. Wenn nun ein unbekanntes Fahrerverhalten mit diesen Sequenzen verglichen wird und sich eine Ähnlichkeit herausstellt, so ist die Wahrscheinlichkeit hoch, dass dieses Verhalten auf ein ähnliches Fahrmanöver hindeutet. Diese Sequenzen können, analog zur Nutzung eines Zustandsautomaten bei Bauer (2011), für einen Vergleich von Fahrerverhalten verwendet werden. Dazu ist ein Verfahren des Vergleiches notwendig. Einige Verfahren, wie künstliche neuronale Netze oder Hidden-Markov-Modelle, sind dazu

---

in der Lage, weisen jedoch black-box (Neuronale Netze) bzw. kein vollständiges white-box Verhalten (HMM) auf.

Das nichtparametrische **k-Nearest-Neighbor** (k-NN) Verfahren bietet die Möglichkeit, unbekannte Sequenzen mit zuvor erlernten Sequenzen, welche in dieser Arbeit natürliches Fahrerverhalten in definierten Situationen repräsentieren, zu vergleichen und mit dem Ziel einer Klassifikation eine Ähnlichkeit zu berechnen. Durch die niedrige erreichbare Fehlerrate und des white-box Verhaltens ist dieses Verfahren geeignet, um es für eine Prädiktion von Fahrmanövern gemäß der Anforderungen einzusetzen. Zur Nutzung des k-NN Verfahrens ist eine **Distanzmetrik** notwendig, um über die Berechnung von Abständen einer unbekannten Sequenz (dem aktuell zu prädizierenden Fahrerverhalten) zu den bekannten Sequenzen (Trainingsdaten) eine Klassifikation durchzuführen. Viele unterschiedliche Distanzmetriken eignen sich für ein k-NN Verfahren. Am geeignetsten erscheint die Nutzung der **Edit Distance** als Distanzmetrik, da diese geeignet ist, Sequenzen von Elementen miteinander zu vergleichen und eine Ähnlichkeit zu berechnen. Darüber hinaus wurde der Edit Distance bereits eine Eignung für eine Klassifikation von Fahrmanövern nachgewiesen (vgl. Kapitel 2.4). Ein weiterer Vorteil der Edit Distance ist der Umgang mit **Unsicherheiten**, wie sie durch die Varianz des Fahrerverhaltens in identischen Situationen entstehen. Die vorhandenen Unsicherheiten der Merkmale können durch die Nutzung dieser Distanzmetrik aktiv adressiert und nicht nur durch die Robustheit des Systems kompensiert werden. Dadurch wird voraussichtlich eine höhere Detektionsqualität erreicht und darüber hinaus der Punkt der Anforderungen zum Umgang mit Unsicherheiten abgedeckt.

Mit Hilfe dieser Distanzmetrik ist es dem k-NN-Verfahren möglich, einen Abstand zwischen einer unbekannten Sequenz und bekannten Sequenzen zu berechnen. Dazu bedarf es einer aufbereiteten Datenbasis aller bekannten Sequenzen. Das Verfahren berechnet den Abstand der gesuchten Sequenz zu allen gespeicherten Sequenzen. Zur Klassifikation ist als freier Parameter des Verfahrens ein  $k$  festzulegen, welches die Anzahl der zugrunde liegenden ähnlichsten Sequenzen zur Klassifikation nutzt. Da im Rahmen des k-NN Verfahrens in jedem Rechenschritt alle Abstände berechnet werden, wäre es vorteilhaft, alle Informationen zu nutzen und eine Klassifikation nicht nur von einem Abstand bestimmen zu lassen, wie es bei einer Wahl von  $k = 1$  der Fall ist. Alle Sequenzen jedoch gleichmäßig in die Klassifizierung einfließen zu lassen, wäre nicht sinnvoll, da dadurch Klassen mit höherer Anzahl an Sequenzen häufiger als andere erkannt werden, unabhängig von der gesuchten Sequenz. Daher ist die Ähnlichkeit der Sequenzen bei der Klassifizierung zu berücksichtigen. Eine zielführende Möglichkeit ist, die Abstände gewichtet zueinander zu summieren, um einen Gesamtabstand der gesuchten Sequenz zu den bekannten Sequenzen zu berechnen. Ein geringer Gesamtabstand würde dann auf eine hohe Wahrscheinlichkeit der Ähnlichkeit der untersuchten Sequenzen hindeuten. Eine **geometrische Reihe** besitzt die Möglichkeit, diese Abstände entsprechend ihrer Eigenschaften zur Berechnung eines gewichteten Abstandes miteinander zu verknüpfen, weshalb diese zur Berechnung des Abstandes verwendet wird.

k-NN-Verfahren besitzen als Nachteil einen hohen **Speicher- und Rechenbedarf**. Daher sollte dieser Umstand aktiv beim Design berücksichtigt werden. Der Ressourcenbedarf wächst bei diesem nichtparametrischen Verfahren mit der Anzahl der zugrunde liegenden Vergleichssamples an. Eine Begrenzung dieser Anzahl ist zur Erzielung eines echtzeitfähigen Algorithmus dabei erstrebenswert. Eine einfache Reduktion der Samples würde in einer geringeren Berücksichtigung der Varianzen des Fahrerverhaltens resultieren. Eine Möglichkeit ist, da verschiedene Fahrmanöver zum Teil verschiedene Muster des Fahrerverhaltens beinhalten, für jedes Fahrmanöver eine eigene Datenbank aufzubauen. Dieses hat den Vorteil, dass im Unterschied zu einer großen allumfassenden Datenbank mit sehr komplexen Sequenzen, mehrere kleine Datenbanken mit spezifischen Sequenzen, nur aus den für das jeweilige Manöver spezifischen Merkmalen, bestehen. Dadurch würden der Rechenaufwand und der Speicherbedarf deutlich sinken. Als weiterer Schritt könnte auch die Berechnung der Vergleiche

---

innerhalb einer Datenbank für eine gewisse Zeit unterbrochen werden, sofern gewisse Merkmale des Fahrerhaltens vorliegen, welche nicht mit dem gespeicherten Muster der Datenbank übereinstimmen und somit das Vorliegen des Fahrmanövers nahezu ausgeschlossen ist. Da die jeweiligen Datenbanken repräsentativ aufgebaut sind, ist die Chance, dabei die Erkennung eines Manövers durch diesen Mechanismus zu unterdrücken, sehr gering.

Für die Anwendung dieser Strategie ist jedoch eine Methode zur Entscheidung, wann welche Datenbanken mit dem aktuellen Fahrerhalten zu vergleichen sind, notwendig. Eine Möglichkeit wäre, **Zustandsautomaten** zum Management der Ressourcen einzusetzen. Diese zeichnen sich durch geringen Rechen- und Speicherbedarf aus. Ein Zustandsautomat kann aus den Sequenzen der jeweiligen **Datenbank** generiert werden, da alle notwendigen Informationen, Zustände und Transitionen in der Datenbank vorhanden sind. Somit repräsentiert ein Zustandsautomat, wie auch schon bei Bauer (2011) zu sehen, das jeweilige Fahrmanöver. Stellt eine unbekannte Sequenz das Verhalten eines Fahrstreifenwechsels dar, so ist anzunehmen, dass nahezu alle Zustände und Transitionen in der Datenbank und dem entsprechenden Zustandsautomaten enthalten sind. Das bedeutet, dass die Analyse dieser Sequenz vollständig im Zustandsautomaten abbildbar ist. Um die Zustandsautomaten für die Moderation der Berechnung einzusetzen ist eine geeignete Verwendung notwendig. Dazu ist es möglich, in einem Zustandsautomaten die **Anfangszustände**, welche aus den Sequenzen als Startzustände entnommen wurden, zu markieren. Sobald eine zu analysierende unbekannte Sequenz einen dieser Zustände enthält, kann die Berechnung des Vergleiches der Sequenz mit der Datenbank mit Hilfe des k-NN Verfahrens gestartet werden, da es sich eventuell um den Anfang des entsprechenden Manövers der Datenbank handelt. Die Beendigung der Berechnung kann durch die analoge Markierung und Auswertung von Endzuständen im Zustandsautomaten erfolgen. Somit ist eine Deaktivierung nach erfolgreicher Durchführung eines Fahrmanövers gewährleistet. Da jedoch gewisse Zustände in mehreren Manövern auftreten können, sollte auch eine Möglichkeit zum Abbruch der Berechnung gegeben sein, falls die Sequenz im weiteren Verlauf sehr unähnlich zu einem Zustandsautomaten ausfällt und ein Endzustand nicht erreicht wird. Dieses kann durch das Auftreten und Detektieren von nicht vorhandenen Transitionen oder das Aktivieren unbekannter Zustände erkannt werden. Wird von der unbekannten Sequenz häufig eine nicht bekannte Transition aktiviert, so ist es sehr wahrscheinlich, dass diese Sequenz nicht das Verhalten des Manövers der zugrunde liegenden Datenbank entspricht und eine Berechnung des kontinuierlichen Abstandsmaßes kann beendet werden. Allerdings sollte eine gewisse Robustheit gegeben sein, damit nicht bei jeder nicht vorhandenen Transition die Berechnung abgebrochen wird. Denn in seltenen Fällen können Zustände oder Transitionen auftreten, welche nicht im Umfang der Trainingsdaten enthalten sind, begründet durch das Auftreten einer individuellen Abweichung im Fahrerverhalten. Weitere Details dazu können Kapitel 5.1 entnommen werden.

Durch den Einsatz verschiedener Datenbanken besteht das System aus einem Verbund verschiedener k-NN-Systeme. Dieses bietet den Vorteil, jedes System durch spezifische Fuzzymengen und –regeln an das jeweilige Fahrmanöver anpassen zu können. Das Design ermöglicht zusammenfassend eine höhere Detektionsgenauigkeit bei reduziertem Rechenaufwand.

Das k-NN Verfahren ist in der Lage die Fahrmanöver durch eine Klassifikation zu erkennen. Weiterhin ist jedoch zusätzlich eine Wahrscheinlichkeitsaussage gefordert. Dazu kann auf das Distanzmaß zurückgegriffen werden. Haben zwei Sequenzen einen sehr geringen Abstand, sind sich im Aufbau also sehr ähnlich, ist die Wahrscheinlichkeit hoch, dass beide Sequenzen dasselbe Fahrmanöver abbilden. Ist der Abstand beider Sequenzen sehr hoch, ist die Wahrscheinlichkeit gering, dass die Fahrmanöver identisch sind. Somit korrelieren die Wahrscheinlichkeit und der Abstand miteinander. Der genaue Zusammenhang zwischen Wahrscheinlichkeit und Abstand kann somit in der Trainingsphase aus den Daten gelernt werden. Die Abbildung von Abstand auf Wahrscheinlichkeit kann mit Hilfe einer Look-up Table abgespeichert und zur Umrechnung verwendet werden. Dabei werden die vorliegenden



---

Fahrmanöver und die berechneten Abstände der Probandenstudie analysiert und in Relation zu den jeweilig ausgeführten Manövern betrachtet. Somit kann für die berechneten Abstände eine statistische Häufigkeit des Auftretens des gesuchten Fahrmanövers berechnet werden. Der Vorteil der Verwendung einer Look-up Table ist dabei, dass keine Annahme über den Verlauf getroffen werden muss, sondern die Daten der Probandenstudie den Verlauf vorgeben und darüber hinaus dieses Verfahren wenig Rechenzeit benötigt.

An manchen Stellen der Entwicklung ist eine Festlegung auf gewisse Parameter notwendig, wie die Wahl der Anzahl der Fuzzymengen je Signal. Da diese Größen die Leistungsfähigkeit des Algorithmus wesentlich beeinflussen können, sollte eine Wahl dieser Zahlen mit Bedacht getroffen werden. Sinnvollerweise kann an Stelle dieser Wahl ein variabler Parameter definiert werden, welcher nach der funktionsfähigen Umsetzung des Algorithmus, anhand der zugrunde liegenden Daten, optimiert wird. Somit kann ein geeignetes Parameterset gefunden werden, welches den Besonderheiten der gestellten Aufgabe entspricht. Diese Parameter werden hier **Designparameter** genannt.

Weiterhin können Merkmale bei der Datenanalyse auftreten, welche nicht bei jeder Manöverausführung präsent sind, aber dennoch wesentlich auf die Ausführung eines Fahrmanövers hindeuten. Als Beispiel sind hier die Nutzung des Blinkers vor dem Fahrstreifenwechsel oder ein Schulterblick zu nennen. Das Verhalten ist damit zu erklären, dass die Nutzung der Kopffrotation unabhängig von den anderen Fahrzeugdaten zu betrachten ist. D.h., ein Fahrer kann dasselbe Manöver mit einer Kopfdrehung zum Schulterblick oder ohne Kopffrotation ausführen, wobei jedoch die Nutzung der Kopfdrehung zum Informationsgewinn vor dem Fahrstreifenwechsel, die Sicherheit des Fahrmanövers erhöht. Lee, Wierwille et al. (2004) stellten fest, dass Fahrer in 30% aller Fahrstreifenwechsel nach links eine Absicherung des Manövers durch eine Kopfbewegung ausgeführt haben und in 14% aller Fälle bei einem Fahrstreifenwechsel nach rechts. Somit ist die Kopffrotation anscheinend kein geeigneter Prädiktor, da diese nur selten in Verbindung mit einem Fahrstreifenwechsel ausgeführt wird. Betrachtet man diesen Aspekt jedoch von dem Standpunkt, dass auf eine Kopffrotation sehr häufig ein Fahrstreifenwechsel folgt und diese Rotation bei einer Geradeausfahrt sehr selten auftritt, ist die Eignung wiederum gut.

Der nächste Aspekt, welcher beachtet werden muss, ist die Analyse untrennbar zusammengehöriger Daten, wie Lenkwinkel und Gierrate, und die mögliche separierte Analyse trennbarer Daten, wie Lenkwinkel und Kopffrotation. Zeigt ein Fahrer, der ein sehr sportliches Fahrverhalten aufweist, keine Kopffrotation um den Fahrstreifenwechsel abzusichern und ein zweiter Fahrer, welcher eine sehr defensive Fahrweise zeigt und jeden Fahrstreifenwechsel mit ein oder mehreren Blicken durch Kopfbewegung absichert, so besteht diese Trainingsdatenbank aus Fahrmanöversequenzen mit hoher Fahrdynamik ohne Kopffrotation sowie Sequenzen mit defensiver Fahrdynamik mit verknüpften Kopfbewegungen. Würde dieser so trainierte Algorithmus an einem Fahrer mit hoher Fahrdynamik, der mit Hilfe von Kopffrotation die Fahrstreifenwechsel absichert, getestet werden, so ist die erwartete Erkennungsrate gering. Ebenso bei einem defensiven Fahrer, welcher keine Kopfbewegung zur Manöverausführung zeigt. Dieses kann im geringen Maße durch die Nutzung der Edit Distance kompensiert werden, führt jedoch zu einer reduzierten Erkennungsleistung. Dieses ist darauf zurückzuführen, dass die Trainingsdaten in diesem Beispiel nicht Kombinationen der Fahrmanöverausführung beinhalten. Eine Variante, die Erkennungsleistung zu erhöhen ist, für jedes signifikant andersartige Fahrerverhalten verschiedene Fahrer zu finden, die die unterschiedlich möglichen Kopfbewegungsprofile repräsentieren. Dadurch würde jedoch die Anzahl der Trainingsdaten stark ansteigen, ohne zusätzlichen Informationsgewinn zu liefern (siehe Tabelle 5).

Tabelle 5: Fahrerverhalten und Kopfrotation

Trainingsproband	Fahrverhalten	Kopfrotation
1	Sportlich	Nein
2	Defensiv	Ja
<b>Testproband</b>		
3	Sportlich	Ja
4	defensiv	Nein
5	Sportlich	Ja
6	Defensiv	Nein

Um den kombinatorisch exponentiellen Anstieg der notwendigen Trainingsdaten zu verhindern, besteht die Möglichkeit, unabhängige Daten zu trennen und einzeln zu betrachten. Dieses wird häufig in dem Verfahren Design of Experiment angewendet (vgl. Condra 2001). Hierbei wird die Variation der untersuchten Haupteffekte geschickt kombiniert, so dass kein kombinatorischer, sondern nur ein linearer Anstieg der Anzahl benötigter Trainingsdaten notwendig ist. Dies bedarf jedoch im weiteren Verlauf einer getrennten Analyse und Verarbeitung. Bezogen auf die Nutzung von Algorithmen mit der Methode des Stacking ist das möglich. Durch das Verbinden verschiedener Algorithmen zu einem Komplex kann dieser Umstand direkt adressiert werden. Für die folgende Umsetzung für entsprechende trennbare Signale kann dieses von Vorteil sein, um eine höhere Erkennungsleistung zu erreichen. Das Ergebnis einer sequentiellen Verarbeitung ist aufgrund der enthaltenen Informationen einer Parallelen gleichwertig.

### 3.6. Programmieren und Umsetzen

Die Umsetzung der Analyse und des Design werden im Kapitel 4, in dem die Vorbereitung, Durchführung und Auswertung der Probandenstudie beschrieben werden, gezeigt. Auch die Analyse der Daten mit dem Bewertungsmaßstab (Kapitel 4.4) und eine gezielte Analyse der Fahrerbeobachtungsdaten (Kapitel 4.3) werden in diesem Kapitel aufgeführt.

Im Kapitel 5 wird die detaillierte Synthese des Algorithmus mit Hilfe der aufbereiteten Daten der Probandenstudie beschrieben. Der Algorithmus basiert, aufgrund der zuvor durchgeführten Analyse, auf einem Fuzzy Logik Anteil zur Transformation der Eingangsdaten (Kapitel 5.1.1), einer Sequenzdatenbank mit den enthaltenen Fahrmanöversequenzen (Kapitel 5.1.2), einem Zustandsautomaten zur Moderation der Rechenkapazität (Kapitel 5.1.3) und einem k-NN Verfahren, unter Nutzung der Edit Distance als Distanzmetrik, zum Vergleich unbekannter Sequenzen mit der Manöverdatenbank (Kapitel 5.1.5).

### 3.7. Test

Nach der Umsetzung und der Synthese des Algorithmus ist die Leistungsfähigkeit in einem Test zu validieren. Durch die **Validierung** mit einem geeigneten Verfahren kann eine mögliche Übertragbarkeit des Algorithmus auf unbekannte Daten abgeschätzt werden. Zum Abschluss der Entwicklung soll dafür

---

eine geeignete Methodik zur Validierung eingesetzt werden. Eine Probandenevaluierung ist für diesen Algorithmus nicht möglich, da der Algorithmus in einem späteren Einsatz in einem Fahrzeug keinen direkten Kontakt zum Fahrer besitzt und nur mittelbar über die Anpassung von Warnzeitpunkten eines Fahrerassistenzsystems auf den Fahrer einwirkt. Daher ist eine Bewertung in diesem Fall sehr häufig durch die Qualität und Leistungsfähigkeit des verwendeten Assistenzsystems beeinflusst (Bias) und liefert keine klare Aussage zur Leistungsfähigkeit des Algorithmus.

Zur Bewertung einer Klassifizierung bieten sich die Nutzung der Wahrheitsmatrix und die Berechnung der Sensitivität und Spezifität an (vgl. Kapitel 2.4). Da der Algorithmus einen kontinuierlichen Wert für die Manöverwahrscheinlichkeit liefert, ist eine Anpassung vorzunehmen und auf eine binäre Klassifikation abzubilden. Dazu wird eine Entscheidungsschwelle der Wahrscheinlichkeit  $p_K$  gewählt, unterhalb dieser das Fahrmanöver als nicht erkannt klassifiziert wird und bei Überschreiten dieses Wertes ein Fahrmanöver als positiv erkannt klassifiziert wird. Dabei gilt ein Fahrmanöver als korrekt erkannt, sobald eine positive Detektion innerhalb eines definierten Zeitfensters (vgl. auch Kapitel 3.5) stattfindet. Durch die Wahl einer geeigneten Wahrscheinlichkeitsschwelle können direkt aus den Daten die Richtig Positiv (TP), Falsch Positiv (FP) und Falsch Negativ (FN) Erkennungen des Algorithmus aus den gelabelten Testdaten berechnet werden. Ein TP Fall liegt vor, wenn der Algorithmus einen Fahrstreifenwechsel nach links erkennt und in den Daten dieses Fahrmanöver als Fahrstreifenwechsel nach links markiert ist. Einzig der Fall der Richtig Negativ (TN) Fälle lässt sich nur schwer bestimmen, da die Definition, wie häufig ein Fahrmanöver korrekt nicht erkannt wird, nicht trivial ist. Jedoch kann das Design der Probandenstudie genutzt werden, um die TN Fälle zu berechnen. Während der Versuche absolvieren die Probanden zu jeder Zeit ein Fahrmanöver gemäß des Fahrmanöverkataloges. Das Versuchsdesign und das Verhalten der Fahrer führen zu einer diskreten Anzahl von Fahrmanövern je Proband über die gesamte Versuchsdauer. Die Anzahl der TN Fälle kann daher mit Hilfe der Anzahl der Fahrmanöver  $n_M$  folgend berechnet werden:  $TN = n_M - TP - FP - FN$ .

Durch die Referenzierung auf diskrete Manöver ist die Evaluierung weniger abhängig von der Wahl der Größe des Zeitfensters. Ein größeres Zeitfenster bei derselben Anzahl an Erkennungen würde die Richtigerkennungsrate in diesem Fall nicht negativ beeinflussen, im Unterschied zur Abtast-Samples basierten Berechnung. Weiterhin ist diese Definition intuitiver, als eine Abtast-Samples basierte Methode zu verstehen, da 50% Richtigerkennungsrate bedeuten, dass 50% aller Manöver richtig erkannt wurden und nicht 50% aller Samples in den definierten Zeitfenstern. Das könnte bedeuten, dass in einem Manöver alle Samples als positiv erkannt werden und im nächsten Zeitfenster keine Richtigerkennung vorliegt. Ein Bezug auf die Samples lässt also keinen Rückschluss auf die Anzahl der erkannten Manöver zu. Mit dieser Anpassung können Spezifität und Sensitivität der Klassifikationsgüte des Algorithmus zur Validierung berechnet werden.

Die Wahl der Entscheidungsschwelle sollte nicht willkürlich, sondern gezielt gewählt werden. Ideal wäre es eine Optimierung zu nutzen, so dass Sensitivität und Spezifität in einem idealen Verhältnis zueinander stehen. Mit Hilfe einer ROC-Analyse lässt sich durch die Variation der Entscheidungsschwelle eine ROC-Kurve erzeugen (vgl. Kapitel 2.4). Dazu wird ein Wert für die Entscheidungsschwelle der Wahrscheinlichkeit  $p_K$  gewählt und die zugehörige Sensitivität und Spezifität berechnet. Im nächsten Schritt wird die Entscheidungsschwelle um 0,1% erhöht und ebenfalls Sensitivität und Spezifität berechnet. Durch die Berechnung von Sensitivität und Spezifität bei allen möglichen Entscheidungsschwellen  $p_K \in [0,1]$ , kann eine ROC-Kurve zur anschaulichen Darstellung gezeichnet werden und die ideale Entscheidungsschwelle, bei dem Wert mit dem günstigsten Verhältnis aus Sensitivität und Spezifität, abgeleitet werden. Führt man dieses Verfahren für verschiedene Algorithmenkonfigurationen aus, kann man direkt die Leistungsfähigkeit beider Algorithmen anhand der Werte vergleichen.

---

Für diese Bewertung sind ein Training des Algorithmus mit Hilfe von Daten und ein Test an Daten notwendig. Sinnvollerweise sollte die Bewertung einer Erkennungsleistung an unbekannten Daten vorgenommen werden, um die Fähigkeit zur Prädiktion von Fahrmanövern an unbekannten Daten abzuschätzen. Dazu wird im Bereich des Maschinenslernens die Datenmenge in Trainings- und Testdaten unterteilt. Da bei einer starren Auswahl, durch die getroffene Auswahl der Trainings- und Testdaten, ein Bias entstehen kann, eignen sich Verfahren zur Kreuzvalidierung, um eine Verzerrung zu minimieren. Diese Verfahren reduzieren einen möglichen Bias, durch mehrere Durchläufe mit verschiedenen gewählten Trainings- und Testdatensätzen, aus der Menge aller Datensätze.

Die leave-one-out Kreuzvalidierung (LOOCV) ist dabei ein vollständiges (exhaustive) Validierungsverfahren, welches unter umsetzbarem Aufwand eine realistische Performanceabschätzung des entwickelten Algorithmus liefern kann. Weitere Validierungsverfahren besitzen entweder geringere Aussagekraft, wie unvollständige Kreuzvalidierungsverfahren, oder sind zeitlich nicht effektiv umsetzbar, wie leave-p-out Kreuzvalidierung. Daher wird der entwickelte Algorithmus mit der Methode der LOOCV validiert. Mit Hilfe der Kreuzvalidierung kann eine Abschätzung der Leistungsfähigkeit des Algorithmus anhand ausgewählter Kennzahlen abgeschätzt werden. Gängige Kennzahlen sind dabei die Richtig- und die Falscherkennungsrate (TPR und FPR). Darüber hinaus ist die Bewertung der Prädiktion im Zeitbereich wesentlich, da ein warnendes FAS dem Fahrer rechtzeitig die wesentlichen Informationen bereitstellen muss und somit eine Fahrmanöverprädiktion mindestens diesen Zeithorizont liefern sollte (Donges 2015). Der Zeithorizont kann mit Hilfe der Erkennungen berechnet werden. Sobald ein Fahrmanöver mit einer Wahrscheinlichkeit oberhalb des optimalen Entscheidungswertes  $p_K$  detektiert wird, wird von diesem Zeitpunkt, bis zur Berührung der Fahrstreifenmarkierung (vgl. Kapitel 2.3), die Zeit berechnet. Durch die Mittelung der berechneten Zeithorizonte bei allen Manövern des Testdatensatzes kann ein mittlerer Zeithorizont  $t_h$  berechnet werden. Dieser ist zur Bewertung der Leitungsfähigkeit ebenso wichtig wie TPR und FPR und wird daher für die vergleichende Betrachtung verschiedener Algorithmuskonfigurationen genutzt.

Weiterhin sollten Algorithmuskonfigurationen ohne Fahrerbeobachtungsdaten mit denen, welche Fahrerbeobachtungsdaten nutzen, verglichen werden, um eine mögliche Verbesserung der Erkennungsleistung oder des Prädiktionshorizontes durch Fahrerbeobachtungsdaten aufzuzeigen. Im Kapitel 5.1.8 und 5.2.2 wird die Validierung verschiedener Algorithmuskonfigurationen ohne und mit Fahrerbeobachtungsdaten ausgeführt und dabei die Leistungsfähigkeit des Algorithmus und die Eignung von Fahrerbeobachtungsdaten für eine Fahrmanöverprädiktion aufgezeigt.

### **3.8. Einsatz**

Der Einsatz des Algorithmus wird im Rahmen dieser Arbeit prototypisch ausgeführt. Dazu wird der Algorithmus in ein Demonstratorfahrzeug integriert, um den Algorithmus auf Funktion und Echtzeitfähigkeit zu testen. Durch eine erfolgreiche Integration sind in Zukunft weitere Tests oder eine Optimierung der Erkennungsleistung möglich. Eine erfolgreiche Implementierung ist darüber hinaus Grundvoraussetzung für die Nutzbarkeit zur Verbesserung von Fahrerassistenzsystemen. Daher werden die Integration und der Test auf Echtzeitfähigkeit im Kapitel 5.2.2 gezeigt. Ein Test in Verbindung mit einem angeschlossenen Fahrerassistenzsystem wird im Rahmen dieser Arbeit aus den zuvor aufgeführten Gründen nicht ausgeführt.

---

## 4. Empirische Studie zur Datengewinnung

---

Kapitel 4 beinhaltet die empirische Studie zur Datengewinnung zur Algorithmenentwicklung, die Merkmalsextraktion (Kapitel 4.2) und die Bewertung der Prädiktoren zur Fahrerbeobachtung (Kapitel 4.3). Im Kapitel 4.4 wird der Bewertungsmaßstab zur quantitativen Bewertung und Auswahl geeigneter Signale und Merkmale für die Algorithmenentwicklung hergeleitet.

### 4.1. Probandenstudie

Zur Entwicklung eines Algorithmus zur Fahrmanöverprädiktion nach dem bottom-up-Ansatz, mit Hilfe von überwachten Maschinenlernverfahren, ist eine umfangreiche Datenbasis notwendig (vgl. Kapitel 3.5). Eine Probandenstudie bietet dabei die geeignete Grundlage notwendige Daten zu sammeln (vgl. Kapitel 3.4).

Die Vorbereitung der Studie wurde von Heuser (2013) und Schildger (2014) im Rahmen ihrer Studienarbeit bzw. Bachelorthesis unterstützt. Die Durchführung der Studie wurde im Rahmen weiterer studentischer Arbeiten unterstützt, denen an dieser Stelle mein Dank gilt.

### Versuchsequipment

Als Versuchsfahrzeug wurde ein Opel Insignia Modelljahr 2012 eingesetzt.



Abbildung 13: Versuchsfahrzeug Opel Insignia Modelljahr 2012

Das Fahrzeug verfügt über eine modifizierte Frontkamera, welche technisch identisch zur Serienkamera ist, im Unterschied jedoch Signale zum Abstand des Fahrzeuges und Winkel zu den Fahrstreifenmarkierungen und die TLC auf dem CAN-Bus übermittelt.

Die Signale vom CAN-Bus wurden unter Einsatz von einem handelsüblichen Laptop und einem CANcase VN1630 unter Nutzung der Software CANape der Firma Vector aufgezeichnet. Es wurden anhand des CAN Protokolls die aufzuzeichnenden Signale ausgewählt und mit Hilfe von dbc-Dateien entschlüsselt.



Abbildung 14: Beispielhafte Integration eines SmartEye Fahrerbeobachtungssystems

In das Versuchsfahrzeug wurde das optische Fahrerbeobachtungssystem SmartEye Pro der Firma SmartEye integriert. Zwei Kameras wurden auf dem Armaturenräger montiert und in Richtung Fahrer ausgerichtet. Dazu wurden zwei Infrarotblitze montiert, welche den Kopf des Fahrers auf ein Signal der Computersteuerung hin beleuchten, damit die Kameras Bilder des Fahrers unter allen Lichtbedingungen aufzeichnen können. Weiterhin wurde ein Computer in das Fahrzeug integriert, welcher die Kamerabilder aufzeichnet und auswertet, die Beleuchtung durch die Infrarotblitze steuert und mit Hilfe der Software SmartEye Pro aus den Kamerabildern die Kopfposition und -bewegung, Augenposition und Blickbewegungen des Fahrers berechnet. Weitere Details zum Messverfahren und den technischen Daten können der Internetseite des Herstellers entnommen werden (Smart Eye AB 2016).

Im nächsten Schritt wurde das Fahrerbeobachtungssystem vermessen. Dabei wurden wesentliche Blickziele, s.g. Areas of Interest (AOIs), eines Fahrers bei der Fahrmanövriervorbereitung identifiziert, mit Hilfe eines 3D-Fahrzeugmessstandes vermessen und in die Software des Fahrerbeobachtungssystems integriert.

Die AOIs wurden definiert und durch eine 3D-Fahrzeugvermessung für das SmartEye System verfügbar gemacht. Hierbei handelte es sich um folgende AOIs: linker/rechter Außenspiegel, Rückspiegel, seitliche Fahrer- und Beifahrerscheibe und vier Bereiche der Frontscheibe (Hauptsichtfeld des Fahrers, rechte Hälfte der Frontscheibe sowie die restlichen Elemente auf der linken Hälfte der Frontscheibe ohne Hauptsichtfeld des Fahrers).





Abbildung 15: Blickziele (Areas of interest, AOI) des Fahrerbeobachtungssystems

Die möglichen Blickziele sind in Abbildung 15 farbig markiert. Die Auswahl beschränkt sich zum einen auf den detektierbaren Bereich des Fahrerbeobachtungssystems und zum anderen auf die, für die primäre Fahraufgabe notwendigen Blickrichtungen. Die Teilung der Frontscheibe in vier Bereiche soll eine Unterscheidbarkeit der Blickzielrichtung genauer zulassen, um möglicherweise Blicke in den Nachbarfahrstreifen von Blicken in Richtung des eigenen Fahrstreifens unterscheiden zu können.

Das SmartEye System ermöglicht die Messung der Kopffrotation des Fahrers in 3 Raumrichtungen (head heading, head pitch, head roll), die Position des Fahrerkopfes als dreidimensionalen Vektor und eine Kopferkennungsqualität  $\epsilon[0..1]$ , wobei 0 keine Erkennung des Fahrerkopfes und der Orientierung und 1 eine maximale Erkennungsqualität beschreibt.

Das SmartEye System ermöglicht über die Messung der Kopfposition und –ausrichtung zusätzlich eine Blickdatenmessung. Es misst die Daten zum horizontalen und vertikalen Blickrichtungswinkel, in Abhängigkeit zum Vektor der Augenpunkte, der Schnittpunkte der Blickrichtung mit den definierten Areas-of-interest (AOI), Informationen zur Augenlidöffnung und -dauer, des Pupillendurchmessers und der Blickerkennungsqualität  $\epsilon[0..1]$ .

### Versuchsaufbau

Die Fahrversuche im kontrollierten Feld entstanden in Kooperation der Adam Opel AG (Opel) mit dem Institut für Arbeitswissenschaft (IAD) der TU Darmstadt auf dem universitätseigenen August-Euler-Flugplatz in Griesheim, bei Darmstadt, im Rahmen des geförderten Verbundprojektes UR:BAN (Manstetten et al. 2013).

Die Probandenstudie im kontrollierten Feld soll möglichst natürliches Fahrerverhalten erzeugen (vgl. Kapitel 3.4). Dazu ist die Auswahl des Versuchsdesigns essentiell, um einerseits möglichst natürliche Fahrsituationen zu erzeugen, aber andererseits auch alle notwendigen Daten aufzeichnen zu können. Dazu soll das Versuchsdesign nicht nur die Fahrmanöver enthalten, welche durch ein System zur Fahrmanöverprädiktion erkannt werden sollen (in diesem Fall der Fahrstreifenwechsel), sondern auch möglichst alle anderen Fahrmanöver, um Daten zum Fahrerverhalten bei diesen Fahrmanövern zu

sammeln. Durch die Berücksichtigung dieser Daten bei der Algorithmenentwicklung besteht die Möglichkeit, Fehlerkennungen bei diesen Fahrmanövern zu reduzieren. Damit die Studie Stadtverkehr möglichst realitätsnah abbildet, wird für die Geschwindigkeit eine häufige Stadtgeschwindigkeit von 50 km/h gewählt. Durch das Aufstellen des Verkehrszeichens 274-55 der StVO, welches die zulässige Höchstgeschwindigkeit von 50 km/h vorschreibt, wurde den Probanden eine stadähnliche Geschwindigkeit vorgegeben. Somit können realitätsnahe Verkehrsbedingungen geschaffen werden, ohne weitere Vorgaben oder Einschränkungen durch Anweisungen des Versuchsleiters an die Probanden geben zu müssen. Der Geschwindigkeitsbereich von 50 km/h verbessert die Vergleichbarkeit mit dem Stadtverkehr. In diesem Geschwindigkeitsbereich ist darüber hinaus ein erhöhtes Unfallrisiko mit schweren Unfallfolgen durch Kollisionen mit dem Gegenverkehr zu erwarten. Bei höheren innerstädtischen Geschwindigkeiten ist oft eine bauliche Trennung der Fahrstreifen unterschiedlicher Fahrtrichtungen vorhanden.

Die Darstellung weiterer Situationen, neben dem Fahrstreifenwechsel, soll ebenfalls unter möglichst realen Bedingungen erfolgen. Dazu wurden zwei Kreuzungssituationen in die Versuchsstrecke integriert. Das Fahrmanöver Anhalten wurde in zwei Ausprägungen realisiert, zum einen durch das Erzeugen einer Kreuzungssituation mit dem Verkehrszeichen 206 („Halt! Vorfahrt gewähren“), welches umgangssprachlich als Stopp-Schild bezeichnet wird, und zum anderen durch eine weitere Kreuzung mit einer Lichtsignalanlage. Dieses verstärkt den Eindruck eines städtischen Umfelds für die Probanden und beinhaltet weitere Fahrmanöver aus dem Fahrmanöverkatalog.

Weiterhin wurden Notsituationen erzeugt, in denen die Fahrer motiviert wurden, eine Kollision durch ein Ausweichen oder Notbremsen zu verhindern. Eine Notbremsung war an der Kreuzungssituation mit Lichtsignalanlage durch einen plötzlichen Wechsel von „Grün“ direkt auf „Rot“ geboten. Durch ein verwendetes, per Lichtschranke aktiviertes, Ausweichhindernis in Form eines plötzlich erscheinenden mit Luft gefüllten Gummischlauches und das Werfen eines handelsüblichen Umzugskartons aus einer Deckung heraus, wurden die Probanden zu Ausweich- oder Notbremsreaktionen motiviert. Details sind Langer et al. (2014) zu entnehmen. Die Versuchsstrecke beinhaltete weiterhin Abschnitte mit Geradeausfahrten und Kurven sowie Situationen einer Folgefahrt und Überholmanöver.

Der genaue Aufbau der Versuchsstrecke ist Abbildung 16 zu entnehmen:




Abbildung 16: Schematischer Aufbau der Versuchsstrecke für die Probandenstudie

Darüber hinaus wurde den Probanden in der Versuchsanleitung erklärt, dass es sich um Fahrversuche für den städtischen Verkehr handelt.



Die wesentlichen Elemente des Versuchsablaufes waren folgende: Die Einführung der Probanden umfasste die Hinweise auf die Gültigkeit und Einhaltung der StVO, dass das Untersuchungsziel das Studieren des natürlichen Fahrerverhaltens in innerstädtischen Szenarien darstelle und den Anweisungen des Versuchsleiters Folge zu leisten sei. Hinweise auf die kritischen Situationen wurden bewusst nicht gegeben, um die Situationen realistisch und unvorhersehbar zu gestalten und das Fahrerverhalten der Probanden nicht zu beeinflussen.

Nach der Kalibrierung des Fahrerbeobachtungssystems und dem Start der Datenaufzeichnung begann der Versuch. Die Probanden wurden während der kompletten Fahrt durch einen Versuchsleiter, welcher im Fahrzeug auf den Rücksitzen saß, begleitet. Der Versuch startete mit zwei Einführungsunden, damit die Probanden das Streckenlayout kennenlernen konnten. Dadurch wurde sichergestellt, dass jeder Proband den Streckenverlauf kennt und mit dem Fahrzeug und der Routenführung vertraut ist.

Der Ablauf der Studie dauerte je Proband ungefähr 45min und ist in Tabelle 6 zusammengefasst.

Tabelle 6: Ablaufplan der Probandenstudie

Runde	Verlangsamen		Fahrstreifenwechsel		Notbremsen		Notausweichen
	STOP-Schild	LSA	Ausweichpylone	Überholen	LSA	Schaumstoffblock	URBAN-Pylone
1	Einführungsunde						
2	Einführungsunde						
3	x	x	x (2li & 2re)				
4	x		x (2li & 2re)	x (45km/h)			
5	x	x	x (2li & 2re)				
6	x		x (2li & 2re)	x (30km/h)			
7	x		x (2li & 2re)	(x)			x (re hinten)
8	x		x (2li & 2re)		x		
9	x		x (li & 2re)				x (re vorne)
10	x		x (2li & 2re)		x	x	
Summe	10		10x li - 10x re		3		2x re

Die Versuche umfassten insgesamt 10 Runden auf der Versuchsstrecke, von denen die letzten 8 für die weitere Auswertung vorgesehen sind. Die Runden 1 und 2 dienten der Einführung. In den folgenden Runden (Runde 3 bis Runde 6) wurden die Probanden mit den unkritischen Situationen konfrontiert. Die kritischen Situationen wurden gezielt in den letzten Runden (Runde 7 bis Runde 10) präsentiert, um das Fahrerverhalten der Probanden in der Versuchsumgebung möglichst natürlich und unverfälscht messen zu können und nicht durch eine Erwartungshaltung von kritischen Situationen zu verfälschen. Weiterhin wurde die Reihenfolge der Darbietung der kritischen Situationen innerhalb des Probandenkollektivs permutiert, um Reihenfolgeeffekte zu minimieren.

Die Realisierung des Fahrmanövers Fahrstreifenwechsel wurde auf der Versuchsstrecke in zwei verschiedenen Ausprägungen (gezwungen und ungezwungen) sowie in beide möglichen Richtungen (FSW nach links und nach rechts), durch das Aufstellen von Leitkegeln, durchgeführt. Fahrstreifenwechsel sind sehr komplexe Fahrmanöver und wurden daher auf einer geraden Strecke absolviert, um die hohe Komplexität von Fahrstreifenwechsel in Kurven zu vermeiden (Berndt et al. 2008). Somit können Daten von Fahrstreifenwechsel mit dem Fokus auf inter- und intraindividuelles Verhalten gesammelt werden, ohne Einflüsse der Straßenführung berücksichtigen zu müssen.

Da in dieser Arbeit der Fokus auf der Prädiktion von FSW liegt, soll im Folgenden dieser Anteil der Studie insbesondere erläutert werden. Die Details zum Versuchsaufbau, zur Versuchsdurchführung und zu weiteren Situationen können den Arbeiten von Heuser (2013), Schildger (2014) und Langer et al. (2014) entnommen werden.

Beim Versuchsaufbau wurden auf einer ehemaligen Landebahn, welche mit Fahrstreifenmarkierungen für zwei Fahrstreifen, in gleiche Richtung verlaufend, versehen ist, insgesamt vier FSW aufgebaut. Davon waren zwei in Richtung von rechts nach links und zwei in Richtung von links nach rechts zu bewältigen. Weiterhin wurden jeweils ein FSW in der Ausprägung „frei“ und ein FSW in der Ausprägung „gezwungen“ dargeboten. Diese verschiedenen Ausprägungen sollten die Probanden motivieren, verschiedenes Verhalten bei der Ausführung der FSW zu zeigen, um die Varianz der aufgezeichneten Daten zu erhöhen.




Abbildung 17: Schematische Darstellung "freier" Fahrstreifenwechsel nach rechts (Langer et al. 2016)

Beim „freien“ FSW lag zwischen dem letzten Leitkegel, welcher die beiden Fahrstreifen voneinander trennt, bis zum ersten Leitkegel, welcher den durch die Probanden befahrenen Fahrstreifen enden lässt, eine 60m Strecke. Dadurch wurde den Probanden ausreichend Platz zur Verfügung gestellt, einen FSW, gemäß ihren Bedürfnissen für Komfort oder Spaß, auszuführen. Die Verengung wurde über eine Strecke von 24m realisiert, nach der der Proband mit dem Versuchsfahrzeug auf den benachbarten Fahrstreifen wechseln sollte.




Abbildung 18: Schematische Darstellung "gezwungener" Fahrstreifenwechsel nach links (Langer et al. 2016)

Der Aufbau des „gezwungenen“ FSW stellte den Probanden einen Streckenabschnitt von 7m zur Verfügung, im Unterschied zu den 60m beim „freien“ FSW. Auch hier waren für den Probanden weitere 24m, auf denen der Ausgangsfahrstreifen verengt wurde, für den Fahrstreifenwechsel vorgesehen.



Abbildung 19: Foto des Versuchsaufbaus "freier" Fahrstreifenwechsel nach links

In Abbildung 19 ist der reale Aufbau im Vergleich zu den schematischen Darstellungen in Abbildung 17 und Abbildung 18 zu erkennen. Hier dargestellt ist der „freie“ Fahrstreifenwechsel nach links mit dem Versuchsfahrzeug der Probandenstudie.



Abbildung 20: Foto des Versuchsaufbaus "gezwungener" Fahrstreifenwechsel nach links

Um andere Verkehrsteilnehmer darzustellen, wurde ein weiteres Versuchsfahrzeug, gefahren von einem Versuchsleiter, eingesetzt. Das Fahrzeug fuhr in verschiedenen Fahrtrunden entweder hinter, vor oder versetzt zum Versuchsfahrzeug der Probanden. Dieses sollte die Probanden zu realistischen Verhaltensweisen beim Fahrstreifenwechsel, wie Spiegel- oder Schulterblicke, motivieren und die Realitätsnähe der Situationen steigern. Weitere Details sind der Arbeit von Schildger (2014) zu entnehmen.

Die Durchführung der Studie und Analyse der Daten wurden durch die Arbeiten von Eurich (2014); Noll (2015); Sahin (2015); Schildger (2014); Zeyrek (2014) unterstützt.

---

Im Rahmen von Vorversuchen mit Experten der Adam Opel AG und des IAD wurde die Eignung der Versuchsbedingungen für die realitätsnahe Darstellung der Fahrmanöver kritisch diskutiert und abschließend als geeignet für die Studie befunden.

### **Probandenkollektiv**

Die Probanden für die Studie wurden aus mehreren Quellen akquiriert. Sie wurden durch Nutzung der Opel internen Probandendatenbank und der IAD Datenbank für Probandenstudien sowie durch direkte Akquise der an der Versuchsdurchführung beteiligten Studenten, bestimmt. Dabei wurde vor allem auf eine möglichst gleichmäßige Verteilung des Geschlechtes und auf eine große Altersspanne der Probanden Wert gelegt, um Fahrerverhalten von jeder möglichen Gruppe aufzeichnen zu können. Bengler et al. (2014) formulierten, dass die Verteilung und Adressierung von FAS an die notwendigen Zielgruppen mit der höchsten Unfallwahrscheinlichkeit, junge, unerfahrene und ältere Fahrer, bisher nicht umgesetzt wurde. Daher ist die Aufnahme dieser Fahrer in das Probandenkollektiv erwünscht, um die Besonderheiten der Fahrzeugführung mit aufzeichnen zu können und bei der Entwicklung des Algorithmus zu berücksichtigen.

Im Rahmen des UR:BAN Projektes wurden zwei Studien mit ähnlichem Versuchsdesign ausgeführt. In dieser Arbeit werden die Daten der zweiten Probandenstudie betrachtet. Aufgrund der Auswertung und erster Ergebnisse der ersten Probandenstudie wurden einige Defizite im Versuchsdesign festgestellt, welches für die Durchführung der zweiten Studie angepasst wurde. Die Erkenntnisse und Optimierungsmöglichkeiten entstanden in Zusammenarbeit mit Schildger (2014). Die drei Verbesserungen werden hier kurz aufgeführt.

Es wurde festgestellt, dass die Probanden während der Ausführung der Fahrstreifenwechsel sehr wenige Spiegelblicke zeigten. Aus der Literatur ist jedoch ersichtlich, dass Fahrstreifenwechsel typischerweise mit Spiegel- oder Schulterblicken abgesichert werden. Die Analyse führte dazu, dass dieses hauptsächlich im Nichtvorhandensein von weiteren Verkehrsteilnehmer-Fahrzeugen auf der Versuchsstrecke begründet lag. Daher wurde für die zweite Probandenstudie ein weiteres VT-Fahrzeug eingesetzt und von einem Versuchsleiter gesteuert. Das VT-Fahrzeug wurde während der Fahrstreifenwechsel in definierten Positionen in der Nähe des Fahrzeuges mit den Probanden gefahren, ohne dieses jedoch in der Ausführung der Fahrstreifenwechsel zu behindern, aber jedoch so relevant, dass die ausgeführten Fahrstreifenwechsel mit zumindest Spiegelblicken abgesichert werden mussten. Das VT-Fahrzeug interagierte dabei nicht immer mit dem Fahrzeug der Probanden, zeigte jedoch Präsenz auf der Teststrecke, so dass die Probanden nicht davon ausgehen konnten, immer alleine auf der Teststrecke zu sein und die Fahrstreifenwechsel ohne absichernde Blicke durchführen zu können. Das VT-Fahrzeug fuhr dabei in einigen Runden vor dem Fahrzeug der Probanden, in weiteren Runden hinter den Probanden im selben Fahrstreifen und in folgenden Runden versetzt hinter den Probanden im Nachbarfahrstreifen. Das Verhalten des VT-Fahrzeuges ist bei allen Probanden gemäß dem Versuchsplan identisch gewesen, um eine Vergleichbarkeit der Situationen zu erhalten.



Abbildung 21: Darstellung und Sichtbarkeit der Positionen des weiteren Fahrzeuges während der Studie

Die Erkennungsleistung und Eigenschaft des Eyetrackingsystems DIKABLIS, welches in der Probandenstudie 2013 eingesetzt wurde, machten ebenfalls eine Anpassung notwendig. Dadurch, dass die Studie im Sommer mit starker Lichteinstrahlung durch die Sonne durchgeführt wurde, ergaben sich schwerwiegende Probleme in der Datenaufzeichnung des Eyetrackingsystems. Die Sonnenstrahlung verhinderte zum Teil die Erkennung des Fahrerblickverhaltens vollständig, so dass nahezu alle Daten nachträglich manuell nachbearbeitet und annotiert werden mussten. Weiterhin ist durch die intrusive Methode der Blickbewegungsmessung des Systems eine Beeinflussung der Probanden und deren Verhalten nicht auszuschließen. Im Hinblick auf eine zukünftige Verwendung von Fahrerbeobachtungssystemen in serienmäßigen Fahrzeugen bieten nichtintrusive Fahrerbeobachtungssysteme, wie fahrzeugfeste Fahrerbeobachtungssysteme, einen großen Vorteil. Daher wurde für die zweite Probandenstudie das Fahrerbeobachtungssystem SmartEye Pro 6 der Firma SmartEye eingesetzt. Ein weiterer Vorteil des Systems ist neben der höheren Bildwiederholrate auch die Möglichkeit, nicht nur Blickbewegungsanalyse, sondern auch Informationen zur Kopforientierung des Fahrers messen zu können.

Die weiteren Verbesserungen betrafen die kritische Situation an der Kreuzung durch die Schaltung der Lichtsignalanlage und das Fehlen eines VT-Fahrzeuges, und im Aufbau die Folgefahrt und das Überholmanöver. Da diese Fahrmanöver nicht im Fokus dieser Arbeit stehen, werden auf die Arbeit und Erkenntnisse von Schildger (2014) verwiesen.

An der Studie im Jahr 2014 nahmen insgesamt 44 Probanden teil. Die Altersverteilung des Probandenkollektivs zeigte ein Durchschnittsalter von 38,4 Jahren mit einer Standardabweichung von 13,6 Jahren und einer Spannweite von 21 bis 65 Jahren. Davon waren 24 männliche Teilnehmer, was einen Anteil von 54,6% entspricht und analog dazu 45,4% weibliche Teilnehmer. Die durchschnittliche Fahrleistung ist der Abbildung 22 zu entnehmen.




Abbildung 22: Durchschnittliche Fahrleistung der Probanden (Langer et al. 2016)

Mehr als die Hälfte der Probanden besitzen eine mittlere jährliche Fahrleistung zwischen 10.000 km und 30.000 km.

Die Probanden der Studie 2014 schätzten ihren Fahrstil folgendermaßen ein:




Abbildung 23: Fahrstil, Selbsteinschätzung der Probanden (Langer et al. 2016)

Genau die Hälfte der Probanden schätzte sich als unauffällige Durchschnittsfahrer ein. Es war kein Fahrer mit einer risikofreudig aggressiven oder wenig routiniert-unentschlossener Selbsteinschätzung dabei. Weiterhin konnten sich drei Probanden auch auf Nachfrage nicht einer der Kategorien zuordnen, was als keine eindeutige Angabe gewertet wurde.

### Statistik zum Fahrerverhalten

Aufgrund von interindividuellen Unterschieden im Fahrerverhalten bei der Manöverausführung entsteht eine Unschärfe in den Merkmalen zur Fahrmanöverprädiktion.






Abbildung 24: Trajektorienverlauf aller Probanden beim Fahrstreifenwechsel nach links mit interindividuellen Unterschieden

Dargestellt sind in Abbildung 24 die mittleren Trajektorien aller Probanden während der Ausführung desselben Fahrstreifenwechsels an derselben Stelle des Versuchsparcours. Hier sind die interindividuellen Unterschiede in der Manöverausführung gut zu erkennen (vgl. auch Kapitel 4.4).

Ein Algorithmus auf Basis von Fuzzy Logik kann Unschärfe direkt modellieren und somit unscharfe Daten verarbeiten. Auch die charakteristische Interpretation von Daten durch Menschen ist gut mit Fuzzy Logik darzustellen (Adamy 2011).

Durch intraindividuelle Unterschiede im Fahrerverhalten entsteht Unsicherheit in den Merkmalen.




Abbildung 25: Trajektorienverlauf eines Probanden beim Fahrstreifenwechsel nach links mit intraindividuellen Unterschieden

Dargestellt sind in Abbildung 25 die Trajektorien eines einzigen Probanden bei der Ausführung desselben Fahrstreifenwechsels an derselben Stelle des Versuchsparcours (weiß) und die mittlere Trajektorie (blau). Zu erkennen sind hierbei die intraindividuellen Schwankungen im Fahrerverhalten in aufeinanderfolgenden Runden.

Diese intraindividuellen Schwankungen müssen bei der Fahrmanöverprädiktion berücksichtigt werden. Würden diese Schwankungen nicht bestehen, könnte mit Hilfe einer sehr eng gewählten Regel ein FSW präzisiert werden, zum Beispiel: Sobald der Lenkwinkel einen Wert  $\vartheta = [5,64^\circ \dots 5,65^\circ]$  erreicht, plant der Fahrer einen FSW nach links. Das entspricht nicht der Realität, wodurch ein Algorithmus Unsicherheiten durch intraindividuelle Schwankungen adressieren muss. Die Verwendung eines Verfahrens mit einem Abstandsmaß, welches eine Schwankungsbreite in den Merkmalen zulässt (k-Nearest-Neighbor mit Edit Distance Distanzmaß, vgl. Kapitel 3.5), ermöglicht es, diesen Aspekt des Fahrerhaltens zu modellieren.

### Statistik der Fahrerbeobachtung

Darüber hinaus wurde die Datenqualität der aufgezeichneten Kopf- und Blickbewegungsdaten gemäß einer Metrik, welche von der Software des SmartEye Pro Fahrerbeobachtungssystems berechnet wird, verglichen.




Abbildung 26: Detektionsqualität des SmartEye Systems bezüglich Blickbewegungs- und Kopfbewegungserkennung



Die Detektionsqualität der Kopfbewegungen war in einem Zeitraum von über 80% der Probandenstudie hervorragend. Nichterkennungen traten hauptsächlich bei sehr hohen Kopfrotationen, wie sehr starken Schulterblicken nach links, oder beim Beantworten der Fragebögen nach den Notsituationen auf.

Die Erkennungsqualität der Blickbewegungen war jedoch in über 50% der Zeit sehr niedrig. Zwar sind die zeitlichen Aussetzer der Erkennung eher von kurzer Natur, was durch ein geeignetes Filterverfahren gemindert werden kann, jedoch ließ das Fahrerbeobachtungssystem in dem verwendeten Aufbau und der Konfiguration mit zwei Kameras keine bessere Detektionsqualität zu. Alle Samples mit einer Erkennungsrate geringer als 0,3 wurden als nicht vorhanden verworfen. Eine tiefergehende Datenanalyse und Datenaufbereitung ist der Arbeit von Achieser (2016) zu entnehmen.

Gemäß Liebner et al. (2012) häufen sich vor einem Fahrstreifenwechsel nach links die Spiegelfixationen, welche auch Spiegelblicke genannt werden können, in den linken Außenspiegel zwischen zwei und fünf Sekunden. Aus der ersten Studie konnten nicht alle Daten verwendet werden. Aus der zweiten Studie wurden 142 Fahrstreifenwechsel nach links analysiert. Die Anzahl ergibt sich aus den 36 analysierbaren Probanden der insgesamt 44 Teilnehmer. Aufgrund von Fehlern in der Datenaufzeichnung, hervorgerufen durch die Messhardware, konnten nicht alle Probandendaten verwendet werden. Je Proband, bis auf eine Ausnahme, wurden 2 Fahrstreifenwechsel nach links analysiert. Die Ergebnisse sind folgende:




Abbildung 27: Verteilung der Spiegelblicke vor Fahrstreifenwechsel nach links in der Probandenstudie (Langer et al. 2016)

Die Verteilung weist eine Häufung der Spiegelblicke zwischen einer und vier Sekunden vor dem Fahrstreifenwechsel auf und ist vergleichbar mit der Verteilung aus Liebner et al. (2012).

Weiterhin wurde die Anzahl der Spiegelblicke untersucht, da für eine nachhaltige Absicherung eines Fahrstreifenwechsels mehrfache Blicke in den Spiegel vermutet werden und diese möglicherweise ein Unterscheidungskriterium für die Prädiktion darstellen können.

In Abbildung 28 ist die Verteilung der Studie zu sehen:



Abbildung 28: Blickhäufigkeiten in die Außen- und Rückspiegel vor den Fahrstreifenwechseln (Langer et al. 2016)

Es erfolgten 129 Blickzuwendungen auf den linken, 80 auf den rechten Außenspiegel und 167 Blickzuwendungen auf den Innenspiegel, was eine Gesamtanzahl von 376 Blickzuwendungen bei 284 untersuchten Fahrstreifenwechsel bedeutete. In der Versuchsreihe wurden bei 37,6% der Fahrstreifenwechsel mehr als ein Spiegelblick beobachtet.

Vor den Fahrstreifenwechseln ist eine Häufung der Spiegelblicke zwischen eins bis vier Sekunden festzustellen, jedoch nicht in dem postulierten Zeitfenster von Liebner et al. (2012). Somit stellen Spiegelblicke einen möglichen frühen Prädiktor zur Fahrmanöverprädiktion des Fahrstreifenwechsels dar. Allerdings trat in der Mehrheit der Fahrstreifenwechsel kein oder nur ein Spiegelblick auf, so dass hieraus die Schwierigkeit der Unterscheidung, aus Sicht der Häufigkeit zwischen Fahrstreifenwechsel und normalen Absicherungsblicken bei der Geradeausfahrt, entstehen kann.

Eine Analyse der Daten hinsichtlich der Schulterblicke vor einem Fahrstreifenwechsel zeigte, dass in 17,5% der Fälle dem Fahrstreifenwechsel ein Schulterblick vorausgeht (Langer et al. 2015) vgl. auch Sommer (2016) und Bauer (2016). Dabei wurden jeweils 40 Fahrstreifenwechsel nach rechts und nach links betrachtet.

Als Ergebnis stellt sich heraus, dass Schulterblicke, falls sie gezeigt werden, auf einen Fahrstreifenwechsel hindeuten, da dieses Verhalten ansonsten nur bei Parkmanövern in sehr niedrigen Geschwindigkeiten auftritt. Allerdings ist die Häufigkeit des Auftretens gering, so dass eine alleinige Nutzung nicht ausreichend für eine Fahrmanöverprädiktion erscheint.

### Statistik Fahrzeugdaten

In der Studie wurde der **Fahrtrichtungsanzeiger** von den Probanden in 75,2% der Fälle bei einem Fahrstreifenwechsel nach links und in 65,2% bei einem Fahrstreifenwechsel nach rechts betätigt. Angelehnt an Lee, Olsen et al. (2004) wurde die Hypothese, dass beim Fahrstreifenwechsel nach links der Fahrtrichtungsanzeiger häufiger betätigt wird abgelehnt. Eine Analyse mit Hilfe des Chi-Quadrat ( $\chi^2$ ) Tests ergab keinen signifikanten Unterschied ( $p=0,058$ ), sondern nur eine Tendenz.

Eine weitere Unterscheidung hinsichtlich der Fahrstreifenwechsel war in unserer Studie durch die „gezwungenen“ und „freien“ Fahrstreifenwechsel gegeben. Von den Probanden wurde in 72,5% der Fälle beim „freien“ Fahrstreifenwechsel geblinkt, beim „gezwungenen“ Fahrstreifenwechsel in 67,4%. Der Chi-Quadrat ( $\chi^2$ ) Test ergab hierbei keinen signifikanten Unterschied ( $p=0,371$ ).

Somit scheint die Nutzung des Fahrtrichtungsanzeigers ein Indiz für einen Fahrstreifenwechsel zu sein, wenn auch kein zuverlässiges. U.a. Schmidt et al. (2014) haben die Hypothese, dass der Blinker zwischen einer und vier Sekunden vor dem Überqueren der Fahrstreifenmarkierung beim Fahrstreifenwechsel aktiviert wird.

Die Ergebnisse sieht man in Abbildung 29.




Abbildung 29: Zeitliche Verteilung der Blinkeraktivierung beim Fahrstreifenwechsel (vgl. Schmidt et al. 2014)

In dieser Studie aktivierten die Probanden zu 87,7% den Blinker im Zeitraum zwischen einer und vier Sekunden vor Überfahren der Fahrstreifenmarkierung mit einer mittleren Aktivierungszeit von  $\mu = 2,44s$  (Standardabweichung  $\sigma = 1,16s$ ). Somit kann die Erkennung der Betätigung des Blinkers einen positiven Einfluss auf eine Prädiktion eines Fahrstreifenwechsels haben.

Vor allem die Frühzeitigkeit deutet auf einen guten Prädiktor hin. Auch die ähnliche Verwendung und Häufigkeit bei den verschiedenen Fahrstreifenwechsel, deutet auf eine ähnliche Nutzung in unseren Versuchen hin und deckt sich dabei mit den Erkenntnissen aus der Literatur. Nachteilig ist jedoch aufzuführen, dass der Blinker nicht bei jedem Fahrstreifenwechsel aktiviert wird und dass es darüber hinaus mehr Situationen gibt, in denen der Blinker verwendet wird, wie beim Abbiegen oder Anhalten am Straßenrand.

#### 4.2. Merkmalsextraktion (Feature Engineering)

Ziel der Merkmalsextraktion ist, die gewonnenen Daten der Probandenstudie zu analysieren, wesentliche Merkmale der zu erkennenden Muster zu finden, um diese für die Synthese des Algorithmus nutzen zu können. Fahrzeugsignale über CAN-Bus sind einfach zu gewinnen, da sie im Bordnetz des Fahrzeuges zum Austausch von Informationen zwischen Steuergeräten in der für die Fahrmanöverprädiktion ausreichenden Genauigkeit und Abtastrate vorliegen und mit geringem technischen Aufwand genutzt werden können. Auch die Kombination zweier oder mehrerer Signale zu neuen Prädiktoren ist möglich und wird im weiteren Verlauf angewendet.

Die gewonnenen Daten der Probandenstudie müssen für die Nutzung aufbereitet werden. Vor allem für die Verwendung von überwachten Maschinenlernverfahren ist dieser Schritt notwendig, da den Daten Kontextinformationen hinzugefügt werden müssen, um das aufgeführte Verfahren einsetzen zu können. Eine Markierung, vgl. Chovan et al. (1994), in der ein Fahrstreifenwechsel mit der

---

Informationsbeschaffungsphase (information gathering) beginnt, ist nicht hilfreich. Diese Definition ist stark abhängig von dem jeweiligen Fahrerverhalten und bietet nicht die Möglichkeit, die Erkennungsqualität sinnvoll zu vergleichen. Die Verwendung der TLC bietet sich in diesem Fall an, da sie einen über alle Probanden einheitlichen Zeitpunkt bei der Ausführung eines Fahrstreifenwechsels beschreibt (vgl. Kapitel 3.4). Somit ist dieser Referenzwert sinnvoll, da auch für eine zeitliche Prädiktion dieser Referenzwert eine Abschätzung der möglichen Wirksamkeit einer Warnung, den Fahrer zu einer Handlung zu bewegen, möglich macht. Für die gewonnenen Versuchsdaten wurde eine Markierung des Fahrstreifenwechsels durch das Erreichen einer  $TLC = 0s$ , bei einem Fahrstreifenwechsel gewählt. Die anderen Fälle, in denen eine entsprechende TLC erreicht wurde, die aber nicht zu einem Fahrstreifenwechsel gehören, wie das Schneiden einer Kurve mit Überfahren der Fahrstreifenmarkierung, wurden nicht als Fahrstreifenwechsel markiert.

Einige Signale sind mit einem Rauschen behaftet. Dieses reduziert die signal-to-noise ratio (SNR) und verschlechtert somit den Informationsgehalt des Signals. Durch die Anwendung eines Filters kann ungewünschtes (in diesem Fall hochfrequentes) Rauschen aus dem Signal entfernt werden und die gewünschten Signalanteile bleiben erhalten. Für die Filterung der **Beschleunigungssignale** und der **Gierrate** wurde ein Butterworth Tiefpaß-Filter mit einer Eckfrequenz von 2Hz eingesetzt. Die Verwendung dieses Filters hat sich bei der Verarbeitung von Signalen mit Rauschen in der Analyse und Einsatz in Steuergeräten bewährt. Die Wahl der Eckfrequenz liegt in einem Bereich, in dem zwar Sensorrauschen oder Störeinflüsse der Fahrbahn herausgefiltert werden, die vom Fahrer verursachten und gewollten Eingaben zur Steuerung der Längs- und Querdynamik jedoch nicht.

Aus dem vom Fahrerbeobachtungssystem SmartEye Pro zur Verfügung stehenden Signalen zu Fahrerkopf- und Blickbewegungsverhalten wurde durch Analyse der ISO 15007 und Berechnung einer Anzahl weiterer abgeleiteter Kennwerte, eine Auswahl von passenden Merkmalen durchgeführt. Details können der Arbeit von Achieser (2016) entnommen werden.

### **Features: Fahrerbeobachtung**

Fahrerbeobachtung bietet die Möglichkeit, sehr frühe Prädiktoren für menschliches Verhalten zu finden, da sie die Informationsaufnahme analysiert.

Dazu wurden Fixationen nach dem Verfahren von Nyström und Holmqvist (2010) berechnet. Es wurden vorweg die Rohdaten mit Hilfe eines Savitzky-Golay Filters zweiter Ordnung (ebenda) mit einer Länge von 6 Samples, was einer Zeitdauer von 0,1s unserer Daten entspricht, eingesetzt. Alle weiteren Zeitpunkte der Blickdaten wurden als Sakkaden gekennzeichnet. Somit konnten neben den Rohdaten, auch zielgerichtete Blicke unter Bewertung von Fixationen und Sakkaden analysiert werden.

Die Daten wurden im Weiteren durch einen Median-Filter 5-ter Ordnung gefiltert. Ein Median-Filter besitzt die Eigenschaft, im Unterschied zu einem Tiefpassfilter, sogenannte Ecken, also nutzbare Daten mit hoher Frequenz, zu erhalten. Darüber hinaus wurden nach der Identifikation von Fixationen die kumulierten Blickdauern in ausgewählte AOIs berechnet und für die weitere Analyse genutzt.

### **Features: Fahrer-Fahrzeug**

Durch Differenzieren kann aus dem Signal der Gaspedalposition die **Gaspedalgeschwindigkeit** berechnet werden. Da durch Differenzieren ein Rauschen abermals verstärkt werden würde, wurden diese Signale mit einem Tiefpass vor dem Differenzieren gefiltert. Da das erhaltene Signal durch die Ableitung wiederum Rauschen enthält, wurde das abgeleitete Signal ein zweites Mal gefiltert, mit derselben Eckfrequenz. Durch die Filterung entsteht aufgrund der Art der Signalbehandlung ein Phasenversatz (Phasenverzug). Dieser ist jedoch gering in Bezug auf die erwartete Erhöhung der SNR.

Es bietet sich an, aufgrund der reduzierten Komplexität bei der Fuzzy-Logik, die Gaspedal- und die Bremspedalposition als ein Signal zu betrachten. Dadurch reduziert sich die Anzahl der Signale um 1, der Informationsgehalt bleibt jedoch identisch. Die Kombination ist möglich, da die Fahrer in den Versuchen niemals Gas- und Bremspedal gleichzeitig betätigt haben. Diese Kombination ist auch deshalb möglich, da sie verschiedene Richtungen derselben Bewegungsrichtung des Fahrzeuges kontrollieren, vergleichbar mit dem Lenken nach links und rechts. Die Kombination von Gas- ( $s_{th}$ ) und Bremspedalposition ( $s_b$ ) wird im weiteren Verlauf **kombinierte Pedalposition** genannt und berechnet sich zu  $s_{th-b} = s_{th} - s_b$ ,  $s_{th-b} \in [-1,1]$ .

Weiterhin wird ein **kumuliertes Blinkersignal** verwendet. Die Verwendung des nicht digitalen Signals der Blinkeraktivierung, sondern eines kumulierten Blinkersignals, besitzt den Vorteil, dass auch die Aktivierungsdauer berücksichtigt werden kann und dieses Signal somit einen höheren Informationsgehalt zur Abschätzung des Zeithorizontes bis zum Manöverbeginn beinhaltet. Das Signal ist wie folgt definiert:

$$bl_{\Sigma,l} = \int_{t-t_h}^t bl_l(\tau) d\tau, \text{ mit } bl_l = 1 \text{ wenn Blinker aktiviert, sonst } bl_l = 0 \text{ und } t_h = 5s$$

### Features: Fahrzeug

Merkmale der Fahrzeugbewegung beinhalten die Längs- und Querbeschleunigung des Fahrzeuges bezüglich eines fahrzeugfesten Koordinatensystems. Weitere Signale zur Beschreibung der Fahrzeugbewegung sind die Fahrzeuglängsgeschwindigkeit und die Gierrate. Diese Signale, außer die Fahrzeuggeschwindigkeit, werden von einem inertialen Messsystem des Fahrzeuges nahe des Fahrzeugmittelpunktes gemessen und sind per CAN-Bus verfügbar. Die Fahrzeuggeschwindigkeit wird mit Hilfe von Raddrehzahlsensoren und der Umrechnung über den Reifenumfang in die Längsgeschwindigkeit bereitgestellt.

### Features: Fahrzeug-Umwelt

Mit Hilfe der Frontkamera, einer Kamera in der oberen Mitte der Frontscheibe, kann die relative Position des Fahrzeuges zu den Fahrstreifenmarkierungen gemessen werden. Relevante Informationen dazu sind der laterale Abstand zu den Fahrstreifenmarkierungen links und rechts, der relative Winkel des Fahrzeuges zu beiden Fahrstreifenmarkierungen und der TLC (vgl. Kapitel 2.4).

### Features: Umwelt

Da in dieser Arbeit ein Algorithmus zur Fahrmanöverprädiktion von Fahrstreifenwechsel mit dem Fokus auf das Fahrerverhalten entwickelt werden soll, beinhalten die Umweltgrößen hauptsächlich nur die Information über das Vorhandensein eines Zielfahrstreifens für den Fahrstreifenwechsel. Eine Beeinflussung des Fahrverhaltens durch das weitere Versuchsfahrzeug wurde bewusst gering gehalten, in dem der Abstand des Fahrzeuges so gewählt wurde, dass zwar absichernde Blicke durch die Fahrer vor der Ausführung von Fahrstreifenwechsel provoziert werden sollten, das Fahrzeug jedoch keinen Motivator oder Inhibitor für einen Fahrstreifenwechsel darstellen sollte. Weitere Signale aus dem Umfeld beeinflussen die Motivation des Fahrers zu einem bestimmten Verhalten, wie beispielsweise ein langsam empfundener Vorfahrer den Fahrer motivieren kann, ein Überholmanöver einzuleiten. Andere Merkmale können den Fahrer daran hindern gewisse Manöver durchzuführen, wie das Fehlen eines Nachbarfahrstreifens für einen FSW. Diese Informationen beeinflussen den Fahrer in der Fahrzeugführung. Mit dem Ziel der Analyse des Fahrerverhaltens wurden diese Einflussfaktoren bewusst moderiert und konstant gehalten.

---

### 4.3. Bewertung der Prädiktoren zur Fahrerbeobachtung

Wie bereits im Kapitel 3.4 angesprochen, ist eine quantitative Aussage zur Eignung von möglichen Merkmalen wünschenswert. Die einfachste Variante für eine große Anzahl von Signalen ist der Test, ob ein Signal während des Fahrstreifenwechsels einen bestimmten Wert über- oder unterschreitet. Dieses ist durch eine einfache Fallunterscheidung mit Hilfe einer Entscheidungsschwelle möglich. Die Definition einer sinnvollen Entscheidungsschwelle wurde durch das Training von Entscheidungsstümpfen realisiert. Zum Beispiel soll hier der horizontale Kopfwinkel betrachtet und eine Entscheidungsschwelle von  $0,5\text{rad}$  angenommen werden. Sobald der Kopfwinkel diesen Wert überschreitet, gilt das Merkmal als erfüllt und es kann auf einen Fahrstreifenwechsel geschlossen werden. Durch einen einfachen Stellvertreteralgorithmus, in diesem Fall Entscheidungsstümpfen, sollen die bestmöglichen Merkmale ausgewählt werden. Ein großer Vorteil dieser Variante ist, eine effiziente Methode zur Prüfung sehr vieler Merkmale zu sein. Die Auswahl der Merkmale zur Fahrerbeobachtung mit Hilfe von decision stumps wurde durch die studentische Arbeit von Achieser (2016) unterstützt. Aufgrund der hohen Anzahl möglicher abgeleiteter Merkmale der Kopf- und Blickbewegung wurde zur Analyse der möglichen Features auf dieses Verfahren zurückgegriffen.

Durch den Studienaufbau wurden die Zeitfenster der analysierten Daten auf  $[-5s, 3s]$  für den gezwungenen und  $[-5s, 5s]$  für den freien Fahrstreifenwechsel nach links, sowie auf  $[-4s, 4s]$  für den gezwungenen und  $[-2.5s, 5s]$  für den freien Fahrstreifenwechsel nach rechts verwendet. Fast das gesamte Probandenkollektiv nutzte bei dem ersten freien Fahrstreifenwechsel den zur Verfügung stehenden Raum der Teststrecke nicht vollständig aus und wechselte zeitnah nach dem gezwungenen Fahrstreifenwechsel nach links den Fahrstreifen wieder nach rechts. Daraufhin wurde der Zeitraum der betrachteten Daten angepasst, um nicht ein Verhalten, das zur Beendigung des vorhergehenden Fahrstreifenwechsels gehört, der Vorbereitung des nachfolgenden Fahrstreifenwechsels zuzuordnen.




Abbildung 30: Verlauf des Lenkwinkels während der Fahrstreifenwechsel und Wahl der Analysegrenzen aus Achieser (2016)

Vor allem nach dem gezwungenen Fahrstreifenwechsel nach links bzw. vor dem freien Fahrstreifenwechsel nach rechts lagen die Haupteinschränkungen im Zeitfenster, da diese Fahrmanöver von nahezu allen Probanden unmittelbar nacheinander ausgeführt wurden.

Weiterhin wurden aus der Analyse die beiden Zeiträume, in denen zum einen die Fahrer nach den Notsituationen die Fragen des Versuchsleiters beantworteten und zum anderen der Zeitraum der unmittelbaren Annäherung an Kreuzungen, durch ausschließliche Nutzung von Daten bei einer Fahrzeuggeschwindigkeit von  $v > 10 \frac{km}{h}$  eingeschränkt.

Um den Umstand der mäßigen Erkennungsqualität zwischen Falscherkennungen und fehlenden Erkennungen zu adressieren und eine quantitative Bewertung der Merkmale durchzuführen, wurde auf eine ROC-Analyse der Ergebnisse der Entscheidungsschümpfe zurückgegriffen. Dabei wurde eine Schwelle der Fehlerkennungsrate von  $FPR = 0,05$  gewählt, um die Merkmale miteinander vergleichen zu können. Diese Schwelle ist dabei hinreichend hoch gewählt, um nicht zu viele Erkennungen zu unterdrücken und nicht irrelevante Signale zu präferieren. Die Zeit bis zum Manöver wird dabei aus den Mittelwerten des Überschreitens der trainierten Entscheidungsschwelle, also vor der entsprechenden Manövermarkierung, berechnet. Zur Vergleichbarkeit wurden auch Fahrzeugsignale mit dieser Metrik aufgenommen, ein Auszug ist in Tabelle 10 zu sehen.

## Kopfbewegungsdaten

Es wurden über 100 abgeleitete Kennwerte der Fahrerkopfbewegung und des Blickverhaltens in der Arbeit von Achieser (2016) analysiert. Ein Auszug ist der Tabelle 7 zu entnehmen.

Tabelle 7: Werte Kopfbewegungsdaten

Signal	Entscheidungs-kriterium	TPR	FPR	AUC	$t_h$ [s]	$t_{h,err}$ [s]
Headpitch [rad]	>0,14	0,764	0,300	0,760	2,89	1,50
Headheading [rad]	>0,50	0,679	0,050	0,938	2,52	1,32
Min Headheading (1s window)[rad]	>0,32	0,337	0,028	0,900	2,07	1,09
Max Headheading (1s window) [rad]	>0,67	0,585	0,033	0,905	2,12	1,57
Headheading standard deviation (1s window) [rad]	>0,22	0,675	0,062	0,918	2,89	1,34
Headheading average (1s window) [rad]	>0,47	0,560	0,039	0,916	2,63	1,00
Headheading skewness (1s window)	>1,28	0,969	0,194	0,983	3,33	2,01
Headheading kurtosis (1s window)	<1,38	0,939	0,249	0,985	3,25	2,19
Headheading anglevelocity [rad/s]	<-0,52	0,914	0,152	0,980	3,17	1,87

Weitere Kennwerte der Kopfbewegungsdaten sind der Arbeit von Achieser (2016) zu entnehmen.

Es ist zu erkennen, dass es bessere und weniger geeignete abgeleitete Werte für die Fahrmanöverprädiktion gibt. Unter anderem ist der reine horizontale Kopfwinkel einer der besten Prädiktoren, bezogen auf geringe Fehlerkennungsraten mit einem zeitgleich hohen Prädiktionshorizont und geringem zeitlichen Fehler, woraufhin weitere abgeleitete Werte des Kopfwinkels betrachtet wurden.



Tabelle 8: Geeignete Prädiktoren der Kopfbewegungsdaten

Signal	TPR	$t_h$ [s]
Headheading [rad]	0,679	2,52
Min Headheading (1s window)	0,337	2,07
Max Headheading (1s window)	0,585	2,12
Max Headheading (3s window)	0,515	2,05
Avg Headheading (1s window)	0,560	2,63
Headheading standard deviation (1s window)	0,650	2,85
Headheading standard deviation (3s window)	0,420	2,57
Max Headheading angle velocity (3s window)	0,366	2,81

In Tabelle 8 sind mögliche abgeleitete Werte des horizontalen Kopfwinkels mit einer  $TPR > 30\%$  und einer  $FPR < 5\%$  aufgeführt. Dabei ermöglicht der Kopfwinkel in horizontaler Richtung die beste Manövererkennungsrate. Der abgeleitete Wert des maximalen Kopfwinkels über ein Zeitfenster von 3 Sekunden erreicht die größte Anzahl richtig erkannter Zeitelemente. Dieses resultiert daraus, dass das Maximum über ein Zeitfenster einen Speicher repräsentiert, welcher einen maximalen Kopfwinkel über 3 Sekunden hält, selbst wenn der Kopf nach einem Schulterblick wieder in die Ausgangsposition zurückgedreht wurde. Der reine Kopfwinkel kann während eines Schulterblickes vor einem Fahrmanöver die Schwelle kurzzeitig überschreiten und kurz darauf wieder in die Geradeausrichtung zurückgedreht werden. Das Maximum des Kopfwinkels ist ein Wert, welcher darüber hinaus gut interpretierbar ist.

Weiterhin liefert die Ableitung eines Signals, wie die Kopfwinkelgeschwindigkeit mit  $t_h = 2,96s$ , ein Maximum, bevor das Signal selbst einen Ausschlag bei  $t_h = 2,52s$  zeigt, und liefert somit bei einer vergleichbaren Erkennungsrate eine frühere Möglichkeit, ein Manöver zu erkennen. Die Kopfwinkelgeschwindigkeit zeigt bei einer Kopfrotation zum Schulterblick zwei markante Anstiege. Einen Anstieg beim Beginn der Bewegung nach links und einen bei der Rückwärtsdrehung nach einem Schulterblick nach rechts. Um den Ausschlag bei der Rückdrehung nach einem Schulterblick nach rechts für eine Erkennung von Fahrstreifenwechsel nach links zu unterdrücken, werden die Fälle, in denen der Kopfwinkel vor einem positiven Ausschlag der Kopfwinkelgeschwindigkeit innerhalb von 2 Sekunden mehr als  $0,1rad$  nach rechts aus der Geradeausposition gedreht war, unterdrückt. Dadurch wird verhindert, dass diese Information zu fälschlicher Erkennung von Fahrstreifenwechsel nach links führen würde.

Weitere Kopfsignale besitzen eine eher geringe Eignung, weil sie entweder eine geringe Sensitivität oder eine geringe Spezifität besitzen und sich somit nicht als valider Prädiktor verwenden lassen.

Zusätzlich zu den Kopfbewegungsdaten wurden auch Daten zur Blickbewegung berechnet und analysiert. Es wurden Blickverhältnisse und kumulierte Blickdauern in definierte Blickziele (areas-of-interest, AOI), mit und ohne Berücksichtigung von Fixationen mit unterschiedlichen Zeitintervallen, getestet. Die getesteten Merkmale sind an Werte der ISO 15007 angelehnt. Die Ergebnisse sind Tabelle 9 zu entnehmen.

Tabelle 9: Blickdaten

Signal	Entscheidungs-kriterium	TPR	FPR	AUC	$t_h$ [s]	$t_{h,err}$ [s]
Gazepitch [rad]	$<-0,04$	0,839	0,250	0,934	2,53	2,52
Gazeheading [rad]	$>0,26$	0,639	0,128	0,934	2,90	1,97
Gazeheading average (1s window)	$>0,21$	0,242	0,039	0,868	3,35	1,72
Glance duration proportion LM (1s window)	$>0,00$	0,349	0,027	0,704	2,45	1,46
Glance duration proportion LM (1s window, fixations only)	$>0,00$	0,277	0,014	0,612	3,27	1,20
Glance proportion LM (1s window)	$>0,00$	0,244	0,009	0,608	2,82	1,09

Weitere Kennwerte der Blickbewegungsdaten sind der Arbeit von Achieser (2016) zu entnehmen. Von diesen Blickdaten hat die beste Detektionsrate die Blickverweildauer in das linke Seitenfenster mit einem Zeitfenster von 1s, gefolgt von demselben Wert für den linken Außenspiegel. Dabei ist die AOI linkes Seitenfenster ein, bezogen auf die Detektionsleistung des Messsystems zur Blickbewegung, robusteres Blickziel, aufgrund der Größe im Vergleich zum linken Außenspiegel. Bei größeren Zeitintervallen dreht sich die Eignung der beiden Werte um, analog zu den Erkenntnissen aus Olsen et al. (2005). Jedoch verringert die Vergrößerung des Zeitfensters die Detektionsrate. Die höchste Frühzeitigkeit der Detektion wird von dem Wert des Blickverhältnisses des linken Außenspiegels über ein Zeitfenster von 3s erreicht, gefolgt von dem Wert der Blickrichtung über ein Zeitfenster von 1s.

### Zusammenfassende Bewertung der Fahrerbeobachtung

Aus über 100 Kopfbewegungs- und Blickverhaltensmerkmalen haben sich folgende Merkmale mit einer  $TPR > 30\%$  und einer  $FPR < 5\%$  als am vielversprechendsten für eine Fahrmanöverprädiktion von Fahrstreifenwechseln dargestellt.

- Fahrerbeobachtungssignale:
  - Kopfwinkel
  - Kopfwinkelgeschwindigkeit
  - Relative Häufigkeit von Kopfdrehungen nach links ( $>0,5\text{rad}$ ) der letzten 1s und 5s
  - Relative Häufigkeit von Kopfdrehungen nach rechts ( $<-0,5\text{rad}$ ) der letzten 5s
  - Maximaler Kopfwinkel der letzten 1s und 3s
  - Minimaler Kopfwinkel der letzten 1s und 3s
  - Standardabweichung des Kopfwinkels über 1s und 3s
  - Mittelwert des Kopfwinkels über 1s
  - Maximale Kopfwinkelgeschwindigkeit der letzten 3s
  - Minimale Kopfwinkelgeschwindigkeit der letzten 3s

Die Merkmale zeigten selten eine hohe Spezifität bei gleichzeitiger hoher Sensitivität. Die Fahrerbeobachtungsmerkmale mit hoher Spezifität weisen sehr häufig eine geringe Sensitivität auf, besitzen allerdings das Potential, anstehende Fahrmanöver frühzeitig zu präzisieren.

## Bewertung der Fahrzeugdaten

Dasselbe Verfahren wurde auch für die Bewertung der Fahrzeugdaten angewendet. Die Ergebnisse sind in Tabelle 10 dargestellt.

Tabelle 10: Werte decision stump von Fahrzeugdaten

Signal	Entscheidungs-kriterium	TPR	FPR	AUC	$t_h$ [s]	$t_{h,err}$ [s]
Lateralbeschleunigung [ $\text{m/s}^2$ ]	$<1,50$	0,1691	0,046	0,927	0,89	0,26
Gierrate [ $^\circ/\text{s}$ ]	$>13,84$	0,000	0,033	0,897	N/A	N/A
Lenkwinkel [ $^\circ$ ]	$>58,38$	0,000	0,000	0,893	N/A	N/A
Kumulierte Blinkeraktivierung [s]	$>0,37$	0,457	0,040	0,836	1,43	1,79
Abstand zur Fahrstreifenmarkierung [m]	$>-1,09$	1,000	0,031	0,985	0,23	0,70
Fahrzeugwinkel zur Fahrstreifenmarkierung [rad]	$>0,04$	1,000	0,039	0,970	0,78	1,40
TLC [s]	$<2,00$	0,995	0,036	0,994	1,71	1,11

Hier ist zu erkennen, dass die Signale der Fahrstreifenerkennung hohe Spezifität und Sensitivität aufweisen. Vor allem der Wert der TLC sticht durch hohe Richtig- und niedrige Falscherkennungsraten bei hoher zeitlicher Prädiktion hervor. Der Blinker besitzt ebenfalls ein hohes zeitliches Prädiktionspotential, kann jedoch mit einer Richtigerkennungsrate von unter 50% nicht als zuverlässiger Prädiktor eingeschätzt werden. Erkennbar ist weiterhin, dass dieses Verfahren nicht für alle Signale geeignet ist, da Entscheidungskriterien gelernt werden, welche eine Richtigerkennungsrate von Null erzielen und damit ein Zeithorizont nicht berechnet werden kann (N/A). Somit ist die Entwicklung eines geeigneten Bewertungsmaßstabes sinnvoll und zielführend für eine vergleichende Bewertung und Auswahl möglicher Prädiktoren.

Darüber hinaus eignet sich die TLC sehr gut für eine Manöverprädiktion von Fahrstreifenwechsel und die Features zum Fahrzustand, zur Gierrate und Straßenkrümmung zur Unterdrückung von Fehlerkennungen:

- Fahrzeugsignale:
  - o Fahrzustand (Fahrzeuggeschwindigkeit  $>10\text{km/h}$ )
  - o Gierrate
- Umfeldsignale:
  - o TLC
  - o Straßenkrümmung

Die Merkmale zur Position des Fahrzeuges im Fahrstreifen besitzen eine hohe Spezifität bei einer ebenfalls hohen Sensitivität in einem reduzierten Zeithorizont im Vergleich zu den Daten der Fahrerbeobachtung. Weitere Fahrzeugdaten erreichen keine hohe Sensitivität oder sind mit diesem Verfahren nicht testbar. Da vorherige Arbeiten die Verwendung von Prädiktoren als sinnvoll beschreiben, welche in diesem Test jedoch als nicht geeignet abschneiden, ist der Bedarf für ein besseres Verfahren zur Auswahl der Prädiktoren notwendig.

#### 4.4. Bewertungsmaßstab für Prädiktoren

Die Auswahl geeigneter Prädiktoren mit Hilfe von Entscheidungstümpfen ist ein schnelles und geeignetes Verfahren, zügig eine große Anzahl möglicher Prädiktoren zu analysieren und auf eine begrenzte Menge zu reduzieren. Allerdings besitzt dieses Verfahren Grenzen im Vergleich aller Prädiktoren, weshalb ein weiteres, verbessertes Bewertungsverfahren notwendig erscheint. Zur detaillierten Analyse weniger Signale soll auf ein genaueres Verfahren unter Berücksichtigung von Richtig-, Falsch- und Nichterkennungsraten sowie des Zeithorizontes (vgl. Kapitel 3.4) zurückgegriffen werden. Somit kann detailliert eine quantitative Eignung zur Fahrmanöverprädiktion der Signale berechnet und die Auswahl von Eingangssignalen zur Fahrmanöverprädiktion unterstützt werden.

Entwickelt wurde ein quantitativer Bewertungsfaktor, welcher unter Nutzung eines statistisch fundierten Verfahrens den zeitlichen Horizont und die zeitliche Streuung einer Prädiktion mit der Richtig-, Falsch- und Nichterkennungsrate in ein Verhältnis setzt und somit eine Bewertung der Eignung von Prädiktoren zur Fahrerintentionserkennung zur Auswahl der am besten geeigneten Prädiktoren ermöglicht (vgl. Occam's Razor in Domingos (1999)).

Darüber hinaus wurden Gewichtungsfaktoren in den Bewertungsfaktor integriert. Mit diesen kann der Bewertungsfaktor an den Einsatzzweck des FAS angepasst werden. Benötigt ein sicherheitskritisches FAS eine geringe Fehlauflösungsquote, z.B. ein automatisches System zur Kollisionsvermeidung durch Ausweichen und Bremsen, kann dieser Teil stärker gewichtet werden, um die Eignung der Prädiktoren für diese Fahrerintentionserkennung anzupassen. Ist das Ziel, dem Fahrer eine möglichst frühzeitige Information oder Warnung zu präsentieren, kann der zeitliche Anteil des Bewertungsfaktors stärker gewichtet werden, wodurch die Anzahl der akzeptierten Fehlwarnungen zugunsten der Chance alle Richtigwarnungen präsentieren zu können, zunimmt.

Jeder der angesprochenen Aspekte wird zur Gewichtung der Elemente zueinander mit einem zugehörigen Gewichtungsfaktor multipliziert ( $c_T, c_F, c_N, c_R$ ). Um den Wertebereich des Bewertungsfaktors zu begrenzen, wird durch die Summe der Gewichtungsfaktoren dividiert.

$$a = \frac{(c_T * T + c_F * F + c_N * N + c_R * R)}{(c_T + c_F + c_N + c_R)}$$

Um eine Vergleichbarkeit der Elemente zu erreichen, ist eine Abbildung der Zahlen auf einen einheitlichen Wertebereich wünschenswert. Eine Abbildung auf den Wertebereich von [0,1] wirkt dabei, unter Berücksichtigung der Gewichtungsfaktoren, intuitiv.

Zum Anfang wird ein maximaler Zeithorizont ( $t_{max}$ ) definiert, welcher ein Zeitfenster vor dem Manöverbeginn markiert, in dem Merkmale zur Fahrerintentionserkennung auftreten können. Aufgrund der Eigenschaft der Manöverplanung und Vorbereitung durch den Fahrer kann nur in einem begrenzten Zeitfenster vor einem Manöver davon ausgegangen werden, Merkmale zur Manöverprädiktion zu finden. Ist dieses Zeitfenster zu klein gewählt, können sehr frühe Merkmale rechnerisch nicht berücksichtigt werden. Wird das Zeitfenster zu groß gewählt, könnten Merkmale identifiziert werden, welche sehr früh vor einem Manöver auftreten, aber aufgrund der menschlichen Informationsverarbeitung zum vorhergehenden Manöver gehören und kein Indiz für das folgende Fahrmanöver sind.

Weiterhin gilt für Merkmale, die zeitlich nach dem definierten Zeitfenster auftreten, dass sie nicht mehr zur Prädiktion, sondern nur zur Erkennung verwendet werden können und somit zu keinem Zeitgewinn für die Warnung eines FAS beitragen. Andererseits sind Merkmale, welche vor einem definierten Zeitfenster (maximaler Zeithorizont  $t_{max}$ ) den Grenzwert zur Detektion überschreiten, erwartungsgemäß nicht zu dem Manöver gehörend.

Anhand der Fahrversuchsdaten für den Fahrstreifenwechsel nach links wird die Ermittlung der Formel dargestellt: Abbildung 31 stellt den Verlauf des Lenkwinkelsignals der Probanden während der Ausführung eines FSWs nach links dar.




Abbildung 31: Zeitlicher Verlauf des Lenkwinkels aller Probanden vor einem Fahrstreifenwechsel nach links

In Abbildung 31 ist der zeitliche Verlauf des Lenkwinkels aller Probanden bei der Vorbereitung und Ausführung des Fahrstreifenwechsels nach links dargestellt. Man kann den charakteristischen Ausschlag, das Einlenken nach links sowie das Zurücklenken kurz vor der Berührung der Fahrstreifenmarkierung erkennen. Der Zeitpunkt  $t = 0$  beschreibt dabei das Berühren der Fahrstreifenmarkierung mit dem vorderen linken Reifen, analog zur Definition bei der TLC von Godthelp et al. (1984) (vgl. auch Kapitel 2.4). Weiterhin ist die Streuung des Fahrerverhaltens zu erkennen. Es traten keine zwei identischen Lenkwinkelverläufe auf, obwohl die Situation des Fahrstreifenwechsels durch das Versuchsdesign kontrolliert wurde. Durch die Streuung im Verhalten der Fahrer ist es sinnvoll, statistische Methoden zur Beschreibung des Fahrerverhaltens zu verwenden, um Unterschiede feststellen zu können.

Abbildung 32 stellt die Verteilung des Lenkwinkels in einem Histogramm zum Zeitpunkt  $t = -5,5s$  vor dem FSW dar. Zu diesem Zeitpunkt befinden sich die Probanden in der Geradeausfahrt vor einem Fahrstreifenwechsel.




Abbildung 32: Verteilung des Lenkwinkels aller Probanden beim Fahrstreifenwechsel nach links zum Zeitpunkt  $t = -5,5s$

Zu einem frühen Zeitpunkt vor dem Fahrstreifenwechsel ist bereits in den Daten eine Streuung beim Geradeausfahren der Fahrer zu erkennen. Für eine weiterführende Analyse sind die Eigenschaften der Daten zu beschreiben und auszuwerten. Die statistische Analyse der aufgezeichneten, intervallskalierten Daten zeigt, diese sind nicht normalverteilt (Kolmogorov-Smirnov-Test:  $\alpha = 0,05; p = 0,0035$ ). Aufgrund der Wiederholung von Fahrmanövern durch jeden Probanden (vgl. Kapitel 4.1) sind die vorliegenden Daten verbunden. Durch die Nutzung der mittleren Verläufe, innerhalb der jeweiligen Probanden, können die Daten dennoch als statistisch unabhängig behandelt werden. Somit sind die Eigenschaften der vorliegenden Daten: intervallskaliert, gepaart/verbunden, nicht normalverteilt und durch Mittelung der einzelnen Runden unabhängig.

Die Eigenschaften der Daten erlauben die Verwendung des Friedman-Tests zur Betrachtung von signifikanten Veränderungen. Der Friedman-Test ist ein nicht parametrisches statistisches Verfahren zum Test des Lageparameters der Verteilung gepaarter Stichproben. Er ist die parameterfreie Alternative zur ANOVA mit Messwiederholung (Bortz und Schuster, 2010).




Abbildung 33: Grafische Darstellung des Friedman-Tests zur Bestimmung des Zeitpunktes  $t^*$

Der Friedman-Test vergleicht Differenzen der Mittelwerte um einen Lageparameter verschiedener gereihter Datenpaare. In Abbildung 33 sind die Verteilungen des Lenkwinkelverlaufes desselben Fahrstreifenwechsels in 0,05s dauernden zeitdiskreten Abschnitten dargestellt. Der Test identifiziert ab dem Zeitpunkt  $t^*$  einen signifikanten Unterschied der Verteilungen (in rot markiert) in Bezug auf die Daten zu einem frühen Zeitpunkt (grau markiert) vor dem Fahrstreifenwechsel.

Mit Hilfe dieses Tests kann ein zeitlicher Erwartungswert berechnet werden. Der zeitliche Erwartungswert eines Merkmals ist definiert mit dem Zeitpunkt, zu dem sich die Verteilung des Merkmals vor einem zu erkennenden Fahrmanöver signifikant von dem Verhalten beim Geradeausfahren unterscheidet. Der Friedman-Test vergleicht dabei die Verteilungen der untersuchten Variablen aller Zeitpunkte vor der Ausführung des FSW miteinander.

Der Zeitpunkt, zu dem sich die Verteilung des Prädiktors signifikant (Signifikanzniveau  $\alpha = 0,05$ ) von der Ausgangsverteilung unterscheidet, wird als zeitlicher Prädiktionshorizont  $t^*$  definiert. Hierbei gilt zur Bewertung des Prädiktors, je weiter  $t^*$  von der Manövermarkierung entfernt liegt, desto besser ist der Wert.

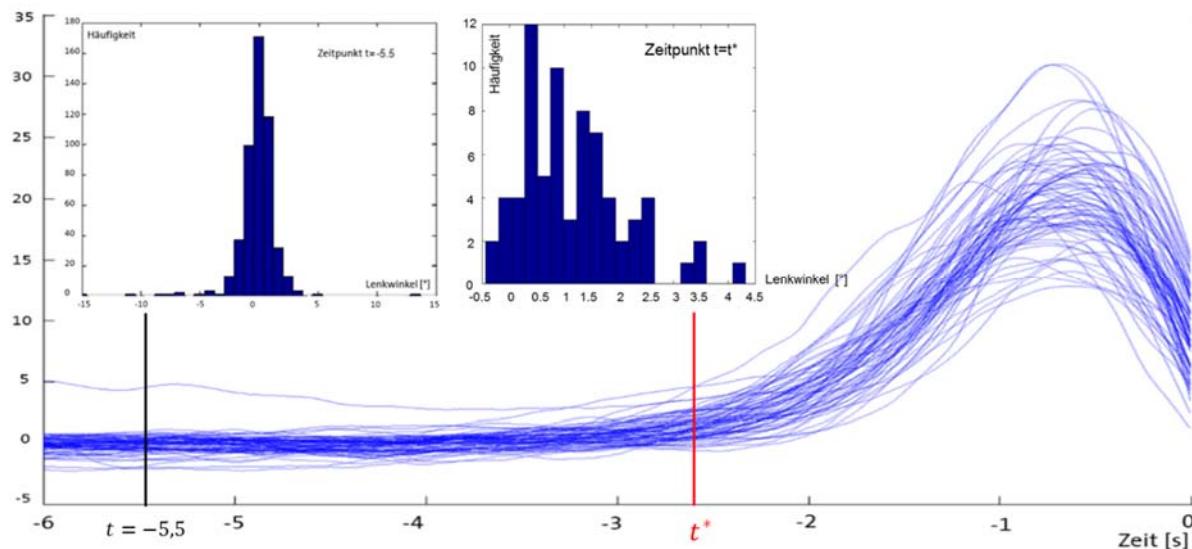


Abbildung 34: Darstellung der Verteilung des Lenkwinkels zu den Zeitpunkten  $t = -5,5s$  und  $t = t^*$  in Relation zu dem zeitlichen Verlauf des Lenkwinkels

In Abbildung 34 werden zur Grafik aus Abbildung 31 der Referenzwert für den Friedman-Test zum Zeitpunkt  $t = -5,5s$  und der ermittelte Prädiktionshorizont  $t^*$  sowie die dazugehörigen Verteilungen des Lenkwinkels gezeigt. Hieran kann man die Bestimmung des Prädiktionshorizontes  $t^*$  im zeitlichen Verlauf der Lenkwinkelsignale erkennen.

Zum Zeitpunkt  $t^*$  wird nun die vorliegende Verteilung des untersuchten Signals detailliert analysiert. Um diese Verteilung für die weitere Verwendung hinreichend genau zu beschreiben, wird der Median der Verteilung berechnet. Die Nutzung des Medians eignet sich insbesondere für die vorliegenden nicht normalverteilten Daten, da dieser im Vergleich zum Mittelwert robust gegenüber Ausreißern und für unsymmetrische Verteilungen besser zu interpretieren ist (Bortz und Schuster 2010).

Der Median an dem Zeitpunkt  $t^*$  wird als Value-of-interest (VOI) definiert (Abbildung 35).




Abbildung 35: Verteilung des Lenkwinkels beim Fahrstreifenwechsel nach links zum Zeitpunkt  $t^*$  und Darstellung des Value-of-interest (VOI)



In Abbildung 35 ist der VOI in der Verteilung des Lenkwinkelsignals zum Zeitpunkt  $t^*$  dargestellt. Die Abbildung stellt dabei die Häufigkeit des auftretenden Lenkwinkels über den Wert zum Zeitpunkt  $t^*$  dar. Der VOI ist ein beschreibendes Kriterium der Verteilung eines Merkmals, welcher zum Zeitpunkt  $t^*$  relevant ist. Dieser Wert wird als Referenz für die weiteren Schritte benötigt.

Bei der Berechnung des zeitlichen Horizontes entsteht aufgrund der Eigenschaft der Daten eine zeitliche Unsicherheit bzw. Streuung. Mit Hilfe des VOI wird im weiteren Verlauf die zeitliche Streuung des Prädiktionshorizontes berechnet. Zur Beschreibung einer Normalverteilung reicht das Wissen des Mittelwertes und der Standardabweichung aus. Bei einer freien Verteilung ist die Lage nicht symmetrisch zum Mittelwert. Daher benötigt man zusätzlich zum Mittelwert oder Median, in diesem Fall der VOI, einen Wert für eine obere und untere Schranke der Verteilung. Da ein einheitliches Verfahren für alle verwendeten Signalverläufe gesucht wird, wird nicht von einer vorgegebenen Verteilung der Daten ausgegangen. Daher wird zur Berechnung der zeitlichen Streuung und genaueren Beschreibung der Daten von einer freien Verteilung der Daten ausgegangen. Es wird berechnet, zu welchem Zeitpunkt ( $t_1$ ) 5% des Probandenkollektivs den VOI vor dem Manöver erreichen und zu welchem Zeitpunkt 95% des Kollektivs ( $t_2$ ) diesen Wert erreichen. Die Differenz dieser Werte sollte so klein wie möglich sein, da durch eine geringe zeitliche Streuung eines Prädiktors die Genauigkeit der zeitlichen Prädiktion steigt. In Abbildung 36 ist dargestellt, zu welchem Zeitpunkt die Probanden in dem genutzten Beispiel den VOI des Lenkwinkels erreichen.




Abbildung 36: Zeitliche Häufigkeitsverteilung des Erreichens von *Lenkwinkel = VOI* beim Fahrstreifenwechsel nach links

Hier ist die Häufigkeit dargestellt, zu welchem Zeitpunkt vor dem Fahrstreifenwechsel der Lenkwinkel den Wert des VOI erreicht. Die zeitliche Streuung  $t_s$  ist die Differenz von  $t_2$  und  $t_1$ . Diese wird in der Bewertung der Prädiktoren berücksichtigt, da sie den zeitlichen Horizont der Erkennung eines Manövers beeinflusst. Im weiteren Verlauf wird eine konservative Abschätzung des zeitlichen Vorhersagewertes  $t^*$  gewählt und  $t_2$  für die weitere Berechnung berücksichtigt. Das bedeutet, Referenz für die Bewertung eines Prädiktors ist der Zeitpunkt, an dem 95% der Probanden diesen Wert bei der Ausführung des Fahrstreifenwechsels erreichen bzw. überschreiten.

In Abbildung 37 sind die bisher ermittelten Werte  $t^*$ , VOI,  $t_1$ ,  $t_2$  im Verlauf der Lenkwinkel über die Zeit dargestellt. Man erkennt die Lage und den Zusammenhang der hergeleiteten Kennwerte mit dem Ursprungssignal.




Abbildung 37: Darstellung der Lage von  $t^*$ , 5-/95-Perzentil und VOI im zeitlichen Verlauf des Lenkwinkels beim Fahrstreifenwechsel nach links

In der Abbildung ist der Zusammenhang der Größen zu dem Verlauf des Lenkwinkelsignals der Probanden zu erkennen. Der VOI beschreibt den Median der Verteilung des Lenkwinkels zum Zeitpunkt  $t^*$  und die Perzentile zeigen die zeitliche Streuung. Wünschenswert für einen Prädiktor wäre ein möglichst großer Zeithorizont, damit ein Fahrmanöver möglichst früh erkannt werden kann mit einer sehr niedrigen Streuung, so dass die zeitliche Prädiktion eine hohe Genauigkeit ausweist.

Nachdem die wesentlichen Kennwerte für die zeitliche Prädiktion berechnet wurden, sollen diese in den Bewertungsmaßstab integriert werden. Wie zum Anfang des Abschnitts dargestellt ist eine Normierung des Bewertungsmaßstabs wünschenswert. Um den Zeithorizont zu normieren, also auf den Wertebereich  $[0,1]$  abzubilden, ist eine Zuordnungsvorschrift notwendig.

Die Berechnung wurde mit Hilfe einer Sigmoidfunktion vorgenommen, da diese einer Abbildung auf den Wertebereich  $]0,1[$  entspricht, hat aber als großen Vorteil, gegenüber einer Rampenfunktion, keine Fallunterscheidung innerhalb der Formeldarstellung zu benötigen. Die verwendete Funktion bildet dabei die Eingabewerte auf den Wertebereich  $]0,1[$  ab. Berücksichtigt wird dabei  $t_2$ , welcher den Wert, das Erreichen des VOI durch 95% der Probanden, berücksichtigt und die konservative Abschätzung zum Zeithorizont, bezogen auf die zeitliche Streuung, darstellt. Die beiden Parameter  $c_1$  und  $c_2$  berechnen sich analytisch aus der Forderung, dass die Sigmoidfunktion ähnlich einer Rampe zwischen  $t = 0$  und  $t = t_{max}$  verlaufen soll. Die Funktion wird dadurch so verschoben, dass sie den Bereich zwischen  $t_{max}$  und dem Manöverzeitpunkt  $t = 0s$  gleichmäßig abdeckt und dabei im Mittel die Steigung einer linearen Funktion entspricht.

$$T = \frac{1}{1 + e^{(t^* + t_s + c_2) \cdot c_1}} \text{ mit } c_1 = \frac{4 \cdot \ln(3)}{T_{max}}; c_2 = \frac{1}{2} T_{max}$$

mit  $T \in ]0,1[$

In Abbildung 38 ist der Verlauf einer Sigmoidfunktion (blau) für ein  $t_{max} = -6,0s$  (grün gestrichelt) und zum Vergleich eine Rampenfunktion (rot) dargestellt.




Abbildung 38: Verlauf der Sigmoidfunktion zur Bewertung der Zeit im Vergleich zu einer Rampenfunktion unter Berücksichtigung von  $t_{\max}$

### Erkennungsraten

Als Metrik zur Erkennung bzw. Klassifikation eines Manövers wird die Korrektklassifikationsrate verwendet. Sie berücksichtigt TP, FP, TN, FN. Allerdings ist dies nach Lorenz (2014) nur bei einer gleichmäßigen Verteilung der Klassen möglich. Bei einer ungleichmäßigen Klassenverteilung ist diese Metrik ungeeignet. Liegt eine schiefe Verteilung vor, ist auch das Ergebnis eines Zufallsprozesses nicht gleichverteilt und somit die Aussagekraft der Metrik reduziert. Weitere Details zu diesem Thema finden sich bei Hoch (2009). Unsere Daten beinhalten eine ungleichmäßige Klassenverteilung, weshalb Standardmetriken nicht angewendet werden können und deshalb angepasste Faktoren verwendet werden.

In Abbildung 39 sind ein fiktiver Signalverlauf, die definierten Zeitfenster ( $T_{\max}$ ) vor einer Manöverausführung sowie die richtig, falsch und nicht erkannten Manöver dargestellt.




Abbildung 39: Schematische Darstellung für die Erkennungsfälle richtig positiv, richtig negativ, falsch positiv und falsch negativ anhand eines fiktiven Signalverlaufes und VOI

Sobald der Signalverlauf den VOI überschreitet, wird ein Manöver als erkannt gezählt. Findet die Erkennung innerhalb des Zeitfensters  $t_{max}$  (grün markierte Fläche in Abbildung 39) vor Einleitung eines Manövers statt (dunkelgrüne Linie), so ist diese Erkennung eine TP. Überschreitet der Wert außerhalb des Fensters den VOI, ist dieses eine FP, da das Merkmal entweder zu früh vor einem Manöver anschluss und somit noch nicht zu dem Manöver gezählt werden kann, oder zu spät ausgelöst hat und somit in diesem Fall nicht mehr zu einer Prädiktion, sondern nur zu einer post-hoc Erkennung beitragen kann. Überschreitet das Signal den VOI innerhalb eines Zeitfensters nicht, so gilt das Manöver als FN.

Damit die Anzahl der Erkennungen verschiedener Situationen und Fahrmanöver miteinander verglichen und in dem Bewertungsfaktor berücksichtigt werden können, werden die Erkennungen auf Erkennungsraten umgerechnet, welche unabhängig von der Anzahl der Fälle sind und auf den Bereich zwischen  $[0,1]$  abbilden.

### Richtigerkennungsrate

Zur Berechnung der Richtigerkennungsrate ( $RERK$ ) wird die Anzahl der Richtigerkennungen (TP) auf die Anzahl der zu erkennenden Manöver ( $Anzahl_{Manöver}$ ) bezogen. Notwendig ist das, weil das zeitliche Verhältnis von Fahrstreifenwechsel zu allen anderen Fahrmanövern nicht 1:1 beträgt.

Somit wird keine absolute Zahl zum Vergleich herangezogen, sondern es müssen Verhältniszahlen gebildet werden.

Ähnlich zur Bewertung von Klassifikationsgüte mit Hilfe von Receiver-operator-characteristics (ROC) Kurven (Egan 1975, Fawcett 2004), wird eine Klassifikationsgüte in Vergleich zu einem Zufallsprozess gesetzt. Diese Methode wird auch hier verwendet und die Anzahl der Erkennungen in Relation zu einem Zufallsklassifikator berücksichtigt ( $RERK_{Zufall}$ ). Der Anteil  $R$  des Bewertungsfaktors zur Richtigerkennungsrate ergibt sich somit zu:

$$R = \left( 0,5 + \frac{RERK - RERK_{Zufall}}{2 * Anzahl_{Manöver}} \right)$$

In der Formel für  $R$  wird 0,5 addiert, damit der Wert für  $R$  auf das Einheitsintervall  $[0,1]$  abgebildet wird, da ein perfekter Klassifikator höchstens 50% besser, als ein gleichverteiltes Zufallsexperiment sein kann.

Der Zufallsklassifikator orientiert sich dabei an der Gesamtanzahl aller Erkennungen, also die Summe aus Richtig- und Falscherkennungen ( $FERK$ ) und verteilt diese Anzahl gleichförmig über den Betrachtungszeitraum (z.B. zehn Runden eines Probanden). Abgeschätzt wird dann, wie wahrscheinlich das Auftreten des Merkmals ist und wie häufig es vorkommt, dass eine oder mehrere Erkennungen in den markierten Manöverzeiträumen liegen.  $RERK_{Zufall}$  berechnet sich zu:

$$RERK_{Zufall} = (RERK + FERK) * \frac{Anzahl_{Zeitschritte \text{ im Manöver}}}{Anzahl_{alle \text{ Zeitschritte}}}$$

### Falscherkennungsrate

Zur Bestimmung der Falscherkennungsrate wird die Anzahl der Falscherkennungen auf die Anzahl der Testzeitpunkte außerhalb der zu erkennenden Manöver bezogen. Die Anzahl hängt von der verwendeten Applikation ab und ist in diesem Fall auf zehn Rechenschritte je Sekunde (identisch zum Algorithmus zur Fahrerintentionserkennung) gewählt.

Der Anteil  $F$  des Bewertungsfaktors zur Berücksichtigung der Falscherkennungsrate berechnet sich zu:

$$F = \frac{\text{Zeitpunkte}_{\text{au\ss erhalb Man\ddot o ver}} - FERK}{\text{Zeitpunkte}_{\text{au\ss erhalb Man\ddot o ver}}}$$

### Falsche Nichterkennungsrate

Im nächsten Schritt werden auch die falschen Nichterkennungen berücksichtigt. Zur Bestimmung des Anteils der Nichterkennungen wird die Nichterkennungsrate (*NERK*) in Relation zur Anzahl der Manöver gesetzt. Der Anteil *N* des Bewertungsfaktors, welcher die falsche Nichterkennungsrate beinhaltet, berechnet sich zu:

$$N = \frac{\text{Anzahl}_{\text{Man\ddot o ver}} - NERK}{\text{Anzahl}_{\text{Man\ddot o ver}}}$$

### Korrekte Nichterkennungsrate

Die Verwendung der korrekten Nichterkennungsrate ist aufgrund der stark ungleichen Klassenverteilung nicht sinnvoll (Lorenz 2014). Denn je nachdem wie viele Samples (z.B. Rechenschritte je Sekunde) man zulässt, ändert sich die Anzahl der korrekten Nichterkennungen und beeinflusst das Verhältnis aller anderen Zahlen. Daher wird auf die Verwendung der korrekten Nichterkennungsrate als ein Bestandteil des Bewertungsfaktors verzichtet.

### Gewichtungsfaktor

Da sich die Summanden *F*, *N* und *R* des Bewertungsfaktors im Bereich  $[0,1]$  bewegen und *T* im Bereich  $]0,1[$ , wobei 1 einen sehr guten und 0 einen sehr schlechten Wert für einen Prädiktor darstellt, und die Gewichtungsfaktoren der Teilterme über die Gesamtformel normiert werden, bewegt sich *a* im Wertebereich  $]0,1[$ . Bessere Prädiktoren haben einen höheren Wert als schlechtere Prädiktoren.

$$F, R, N \in [0,1]; T \in ]0,1[; \text{ und } a \in ]0,1[$$

### Bewertung von Prädiktoren

Mit Hilfe des Bewertungsfaktors wurden für den FSW die Eignung der Eingangssignale für die Fahrerintentionserkennung berechnet. In Tabelle 11 sind die Ergebnisse einiger Prädiktoren für einen Fahrstreifenwechsel nach links dargestellt und gemäß ihrer Eignung *a* sortiert.

Tabelle 11: Prädiktoren und Bewertung beim Fahrstreifenwechsel nach links

Prädiktor	$t^*$	$t_2$	VOI	T	F	N	R	a
Time-to-linecrossing $TLC$	-1,52	-0,49	2,00	0,146	0,962	0,998	0,513	0,655
Winkel des Fahrzeuges zur Fahrstreifenmarkierung $\alpha_{head}$	-2,78	-0,83	0,01	0,187	0,877	1,000	0,513	0,644
Abstand zur Fahrstreifenmarkierung $d_{lat}$	-2,19	-0,36	-1,35	0,132	0,865	1,000	0,513	0,627
Querbesehleunigung $a_{lat}$	-2,10	0,00	0,46	0,100	0,880	0,998	0,513	0,623
Gierrate $\Psi$	-2,36	0,00	1,26	0,100	0,868	0,984	0,514	0,616
Lenkwinkel $\delta$	-2,32	0,00	5,19	0,100	0,866	0,938	0,512	0,604
Längsbesehleunigung $a_{long}$	-1,18	0,00	0,23	0,100	0,665	0,967	0,513	0,561
Lenkwinkel- geschwindigkeit $\dot{\delta}$	-2,36	0,00	11,48	0,100	0,858	0,606	0,507	0,518
Kopfrichtungswinkel $\beta_{head}$	-2,64	0,00	0,66	0,100	0,959	0,498	0,506	0,516
Kumulierte Blinkdauer $bl_{\Sigma}$	-2,14	0,00	0,37	0,100	0,958	0,467	0,505	0,508
Kombinierte Gas- und Bremspedalposition $s_{th-br}$	-0,99	0,00	30,59	0,100	0,841	0,448	0,505	0,474

Dargestellt werden für die jeweiligen Fahrmanöver zu jedem getesteten Prädiktor der Zeithorizont  $t^*$ , die worst-case Abschätzung zur Streuung  $t_2$ , der value-of-interest VOI, die Werte für die vier Summanden des Bewertungsfaktors ( $T$ ,  $F$ ,  $N$ ,  $R$ ) sowie der Gesamtbewertungsfaktor  $a$ .

Der Fahrstreifenwechsel besitzt als Fahrmanöver hauptsächlich Komponenten der Fahrzeugquerführung. Die Signale, welche Größen zur Messung der Fahrzeugquerführung und -bewegung beinhalten, erzielen positive Ergebnisse bezüglich des Bewertungsfaktors. Signale zur Beschreibung der Fahrzeuglängsführung erzielen eine schlechtere Bewertung hinsichtlich der Eignung zur Prädiktion eines FSW. Das war zu erwarten und indiziert die korrekte Klassifizierung von Prädiktoren mit dem entwickelten Bewertungsfaktor.

Auffällig bei allen Werten ist, dass die Richtigerkennungsklassifikation  $R$  nur Werte nahe 0,5 erreicht. Das ist dem Umstand geschuldet, dass die Prädiktoren, welche hier präsentiert wurden, hauptsächlich Rohsignale darstellen. Da diese Merkmale alleine betrachtet sehr unspezifisch für die Detektion der untersuchten Manöver sind, werden sie nicht nur in den spezifischen Manövern, sondern auch in vielen anderen Manövern aktiviert. Dadurch verbessert sich automatisch, entsprechend der oben aufgeführten Definition, der Zufallsprozess zur Erkennung auf Grundlage der Zufallsverteilung und verschlechtert somit den Wert des Summanden  $R$  des Bewertungsfaktors.

---

## Einflussanalyse

$t^*$  beeinflusst direkt den Wert  $T$  und darüber hinaus, über den errechneten Wert VOI, die Werte für  $F$ ,  $N$ , und  $R$ . Daher ist die Wahl eines stabilen statistischen Verfahrens essentiell. Wird ein VOI berechnet, welcher nicht nur in dem untersuchten Manöver, sondern auch während anderer Fahrmanöver überschritten wird (z.B. wird der VOI des Lenkwinkels beim FSW auch bei jeder Kurvenfahrt überschritten), so steigt dadurch die Anzahl der Fehlerkennungen. Je mehr Fehlerkennungen berechnet werden, desto höher ist auch die Wahrscheinlichkeit, dass ein Zufallserkenner (die verwendete Referenz für die Richtigerkennungsrate) die Fahrmanöver zufällig richtig erkennt. Dadurch sinkt folgerichtig die Bewertung der Richtigerkennungsrate  $R$ . Die Falsch- und die Nichterkennungsrate sind in dem Maße von dem VOI abhängig, dass, falls der VOI höher gewählt werden würde, weniger Fehlerkennungen erzeugt werden, aber auch mehr Nichterkennungen entstehen.

## Bewertungsfaktor Fazit

Entwickelt wurde in diesem Abschnitt ein Bewertungsfaktor, welcher den zeitlichen Horizont und die zeitliche Streuung einer Prädiktion mit der Richtig-, Falsch- und Nichterkennungsrate zueinander in ein Verhältnis setzt und somit eine Bewertung der Eignung von Prädiktoren zur Fahrerintentionserkennung ermöglicht.

Mit dem vorgestellten Bewertungsfaktor ist es möglich, Prädiktoren quantitativ miteinander zu vergleichen und eine Reihenfolge der Eignung festzulegen. Entsprechend der vorhandenen Rechenkapazität und der geplanten (Echtzeit-)Anwendung, können die maximal mögliche Anzahl an Prädiktoren mit der höchsten Eignung ausgewählt und als Eingangsgrößen für einen Algorithmus zur Fahrerintentionserkennung benutzt werden.

Die Abschätzung der Eignung der Prädiktoren beinhaltet die Eignung als Einzelfaktor. Ein Test des sinnvollen Zusammenwirkens mehrerer Faktoren zur Fahrerintentionserkennung ist durch die Nutzung der Erkenntnisse zur Auswahl der Eingangsgrößen für den Algorithmus zur Fahrerintentionserkennung möglich. Dazu werden im Kapitel 5 mehrere Algorithmuskonfigurationen mit verschiedenen Kombinationen von Eingangsgrößen aufgebaut und getestet, um die Bewertung der Prädiktoren zu validieren und eine Leistungsfähigkeit von mehreren Prädiktoren im Zusammenspiel bewerten zu können.

---

## 5. Algorithmenentwicklung

---

In diesem Kapitel wird anhand der Entwicklungsmethodik ein Algorithmus zur Fahrmanöverprädiktion auf der Basis von Fuzzy Logik und Edit Distance entwickelt und validiert (Kapitel 5.1). Weiterhin werden Fahrerbeobachtungsdaten in den Algorithmus integriert und die Leistungsfähigkeit mit vorigem Algorithmus verglichen (Kapitel 5.2).

Der Algorithmus zur Fahrmanöverprädiktion berechnet aus ausgewählten Eingangsgrößen das anstehende Fahrmanöver (hier: Fahrstreifenwechsel). Dazu wird das anstehende Fahrmanöver **klassifiziert** und die Klassifikation mit einer **probabilistischen Wahrscheinlichkeitsabschätzung** hinterlegt. Weiterhin gibt der Algorithmus einen Prädiktionshorizont aus, um für Zielassistentensysteme den richtigen Zeitpunkt für eine Fahrerinformation bestimmen zu können (**Regression**). Der Algorithmus ist ein **white-box** Modell und wird mit Hilfe des **Bottom up** Ansatzes mit Verfahren des **überwachten Maschinlernens** entwickelt. Er ist bezüglich der **Eingangsgrößen modular** aufgebaut, damit bei neuen Erkenntnissen weitere Eingangssignale hinzugefügt oder ausgetauscht werden können und verschiedene Konfigurationen zum Vergleich einfach aufbaubar sind. Wichtige Voraussetzung für den Algorithmus ist dabei die **Echtzeitfähigkeit** auf einer Zielhardware. Dieses ermöglicht einem angeschlossenen Fahrerassistenzsystem rechtzeitig und in einer ausreichenden Häufigkeit, Fahrerinformationen an die prädizierte Fahrerabsicht anzupassen. Weiterhin soll der Algorithmus natürliches **Fahrerverhalten repräsentieren**. Wie in den Kapiteln 2.4 und 3. erläutert, ist Fuzzy Logik hochgradig für dieses Anwendungsgebiet geeignet, da es diese **Unschärfe** direkt modelliert.

Durch das Auftreten verschiedener Merkmale zu unterschiedlichen Zeitpunkten vor und während der Manöverausführung arbeitet der Algorithmus mit **time-series data**. Durch die Modellierung der Fuzzy-Regelbasis als Zustandsautomat (vgl. auch Bauer 2011) kann eine Aktivierung verschiedener Fuzzy-Regeln über einen zeitlichen Ablauf beschrieben werden.

**Unsicherheiten** in den Merkmalen der Fahrmanöverausführung, die zum Beispiel durch **intraindividuell** verschiedenes Fahrerverhalten auftreten, werden durch die Nutzung von Merkmalssequenzen und dem Einsatz eines **k-Nearest-Neighbor** Verfahrens, unter Nutzung der **Edit Distance** als Distanzmetrik, adressiert. Die Ergebnisse der Klassifikation können somit in eine Eintrittswahrscheinlichkeit eines Fahrmanövers und in einen Zeithorizont bis zum Eintritt dieses Fahrmanövers umgerechnet werden. Zur Abschätzung der Leistungsfähigkeit und zur **Validierung** wird der Algorithmus mit Hilfe des leave-one-out Kreuzvalidierungsverfahrens validiert.

Im Kapitel 5.2 werden die Daten der **Fahrerbeobachtung** im entwickelten Algorithmus aufgezeigt. Durch das verwendete Distanzmaß wird in diesem Kapitel auch die Kombination des entwickelten Algorithmus mit Entscheidungs- und Regressionsbäumen, mit Hilfe des Verfahrens des **Stacking** gezeigt, um die Performance zu steigern.

### 5.1. Algorithmus zur Fahrmanöverprädiktion

In diesem Abschnitt werden der Aufbau und die Funktionsweise des Algorithmus im Detail beschrieben. Die vorverarbeiteten Signale werden fuzzifiziert (Kapitel 5.1.1). Daraufhin werden die Aktivierungen der Fuzzymengen über die Zeit der Manöverausführung als Fahrerverhaltenssequenz gespeichert (Kapitel 5.1.2). Im nächsten Schritt wird aus allen in den Daten aufgetretenen Zuständen der Zustandsautomat aufgebaut (Kapitel 5.1.3). Danach wird die Verwendung der Edit Distance Metrik zur Inferenz beschrieben (Kapitel 5.1.4). Es folgt die Inferenz zur Bestimmung der Ähnlichkeit durch ein k-Nearest-Neighbor Verfahren (Kapitel 5.1.5). Darauf folgen die Berechnungen der Wahrscheinlichkeit



und des Zeithorizontes der Fahrmanöver (Kapitel 5.1.6). Im Kapitel 5.1.7 wird auf die Designparameter und ihre Optimierung eingegangen und im Kapitel 5.1.8 validiert.

Kapitel 5.1.9 erweitert den Trainingsdatensatz auf alle nutzbaren Probandendatensätze und bewertet die Ergebnisse. Abbildung 40 gibt einen Überblick über den Aufbau des Algorithmus.

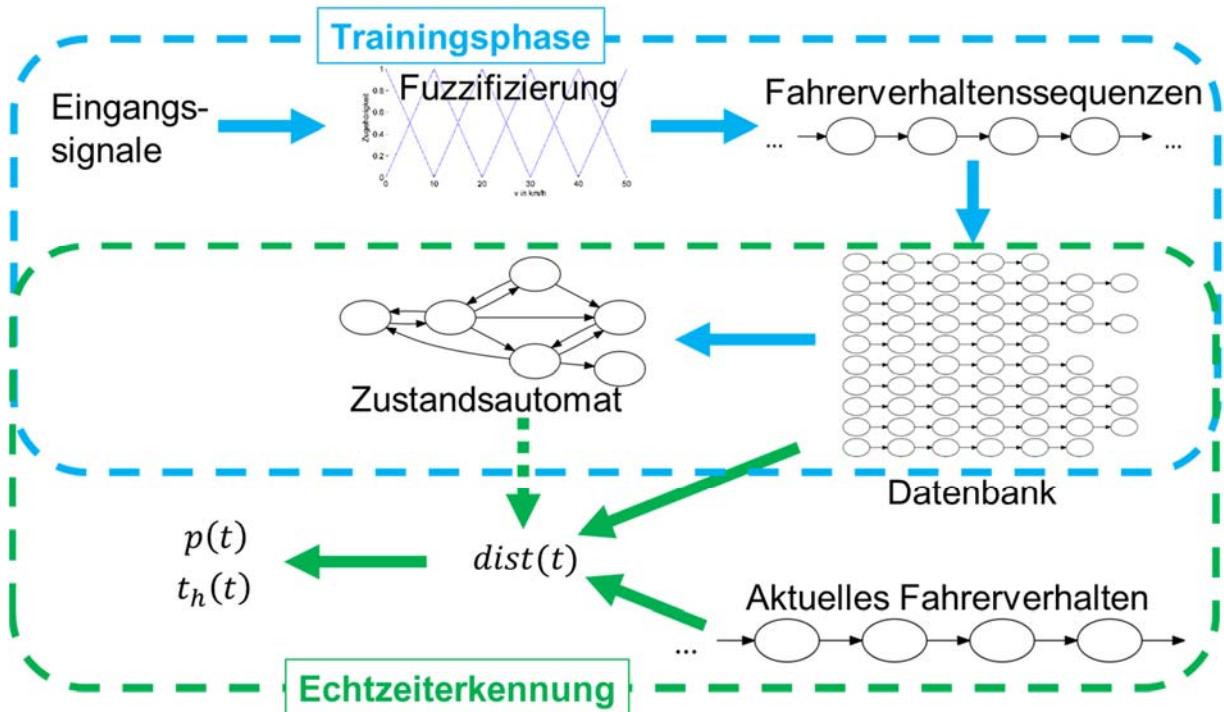


Abbildung 40: Ablaufschema des Algorithmus

Die Entwicklung des Algorithmus wurde durch die studentische Arbeit von Sylla (2015) unterstützt.

#### 5.1.1.1. Fuzzifizierung der Eingangsgrößen

Zur Nutzung der Methoden der Fuzzy Logik werden im ersten Schritt die Eingangsgrößen fuzzifiziert. Eine Variante wäre, die Fuzzymengen manuell durch einen Experten festzulegen. In dieser Arbeit wird Fahrerverhalten durch Fuzzy Logik mathematisch interpretierbar gestaltet. Dieses erscheint hier geeignet, da jedoch jeder Experte verschiedene Meinungen über ein System oder eine Zuordnung besitzt, ist diese Methode nicht vollständig reproduzierbar. Ebenfalls fehlt zur richtigen Einschätzung eine Referenz, somit ist die Festlegung durch Experten nicht optimal. Dieses zeigten auch Hühnhagen et al. (2010). Sie ließen Fuzzymengen durch Experten festlegen und haben sie im weiteren Schritt durch maschinelle Verfahren optimiert. Nachteil dabei ist, dass in dem vorgestellten Verfahren Fuzzymengen über die Variation der Parameter in Daten an manuell eingepflegte Markierungen angepasst werden. Die Position dieser Markierungen ist manuell gewählt, was sehr aufwändig ist und darüber hinaus negativen Einfluss auf die Reproduzierbarkeit hat.

Eine weitere Variante ist, die Fuzzymengen rein aus Daten zu lernen. In der Arbeit von Bauer (2011) wurde ein solches Verfahren eingesetzt, um Fuzzymengen an verschiedene Fahrer anzupassen. Dazu wurden die Parameter der Zugehörigkeitsfunktionen mit Hilfe von Histogrammen an das jeweilige Fahrerverhalten angepasst. Die Histogramme wurden in einer Zeitspanne berechnet und durch Gaußfunktionen approximiert. Diese Gaußfunktionen wurden dann in Zugehörigkeitsfunktionen in Trapezform umgewandelt.

---

Das Ziel dieser Arbeit ist, die Fuzzymengen aus den Daten der Probandenstudie zu lernen und somit die Fuzzymengen optimal an die Fahrversuche und das Fahrerverhalten anzupassen. Jedoch sollen die Fuzzymengen nicht an jeden einzelnen Fahrer angepasst werden, sondern repräsentativ für mehrere verschiedene Fahrer während desselben Fahrmanövers sein. Das Verfahren von Bauer (2011) mit Gaußfunktionen hat sich durch die hohen interindividuellen Unterschiede im Fahrerverhalten als nicht geeignet herausgestellt (Sylla 2015), daher wurde in dieser Arbeit ein anderes Verfahren eingesetzt.

Die Fuzzifizierung von Eingangsgrößen besitzt folgende Freiheitsgrade:

- Form der Zugehörigkeitsfunktion
- Parameter (Abhängig von der Zugehörigkeitsfunktion)
- Anzahl der Fuzzymengen
- Lage der Fuzzymengen

Die Anzahl der Fuzzymengen wurde im ersten Schritt mit Expertenwissen festgelegt. Dabei wurde sich an der Erfahrung aus Adamy (2011) orientiert: die optimale Anzahl an Fuzzymengen sollte zwischen 3 und 9 betragen. Eine solche Anzahl von Fuzzymengen macht eine Zuordnung von Werten der Eingangsgröße differenzierter verarbeitbar. Eine zu große Anzahl jedoch widerspricht dem Grundgedanken, die menschliche Wahrnehmung von Größen zu repräsentieren. Die Anzahl der Fuzzymengen je Eingangsgröße soll ein Algorithmusparameter sein, welcher in einem späteren Schritt durch Optimierung angepasst wird (Kapitel 5.1.7).

Zur Bestimmung der Lage der Fuzzymengen wurden die Eingangssignale analysiert. Eine Variante wäre, unter der Annahme einer Anzahl von Fuzzymengen, diese gleichmäßig über den Bereich der Eingangsvariablen zu verteilen. Nachteil hierbei ist, dass auch in Bereichen, welche für die Fahrmanöverprädiktion weniger relevant sind, ähnlich viele Mengen verteilt sind, wie in den Bereichen von Relevanz. Besser geeignet ist die Variante, die Fuzzymengen an den Verlauf und die Änderung des Eingangssignals anzupassen (Heine, Sylla et al. 2015; Sylla 2015). Die Details sind der Arbeit von Sylla (2015) zu entnehmen. In den Bereichen, in denen viel Änderung des Signals vorliegt, sollen mehr Fuzzymengen aufgestellt werden, um sensibel auf Änderungen anzusprechen. Die Bereiche, in denen wenig Änderung während der Manöverausführung festzustellen ist, sollten weniger Fuzzymengen enthalten, was aufgrund der geringen Änderung auch ausreichend ist, und dabei den Vorteil der Reduktion der Anzahl der Fuzzymengen je Eingangssignal nutzt.




Abbildung 41: Fuzzifizierung der Eingangsdaten am Beispiel des Lenkwinkels beim Fahrstreifenwechsel nach links

Im oberen Graph ist der Verlauf des Lenkwinkels eines Probanden bei der Ausführung eines Fahrstreifenwechsels nach links dargestellt. Beim Zeitpunkt  $t=0s$  berührt das linke Vorderrad die mittlere Fahrstreifenmarkierung.

Im mittleren Graph ist die Änderung des Lenkwinkels über den Lenkwinkel dargestellt. Die Ableitung korreliert negativ mit der Häufigkeit. In dieser Grafik sieht man, dass im Lenkwinkelbereich  $0-3^\circ$  wenig Änderung während der Ausführung des Fahrstreifenwechsels auftritt. Erst im Bereich zwischen  $3-7^\circ$  treten höhere Änderungen auf. Um eine gute Repräsentation der Änderung über den Verlauf zu erhalten, wurde das Integral im Gesamtbereich des Beispiels in fünf gleichgroße Integrale aufgeteilt. Dadurch entstehen fünf Bereiche, welche sich eignen, um Fuzzymengen festzulegen. Die Grenzen der Integrale definieren dabei sinnvollerweise die Schnittpunkte der Fuzzymengen.

Nach dem Lernen der Grenzen der Fuzzymengen ist im nächsten Schritt der genaue Verlauf der Zugehörigkeitsfunktionen zu definieren. Dazu ist die Wahl der Funktionen notwendig. Trapezfunktionen bieten vier freie Parameter ( $a, b, c, d$ ), sind semantisch gut zu interpretieren und in vielen Anwendungen der Fuzzy Logik bereits erfolgreich angewendet worden.

Mit der Festlegung, dass die Summe aller Fuzzymengen immer „1“ ist, was die natürliche Interpretation vereinfacht (Adamy 2011), können die Lage der Zugehörigkeitsfunktionen auf einen weiteren Parameter und die gelernten Grenzen reduziert werden. Darüber hinaus gehört ein Wert maximal zu zwei Zugehörigkeitsfunktionen gleichzeitig.

Durch die vorhergehenden Schritte sind die Grenzen bzw. der Schnittpunkt der Zugehörigkeitsfunktionen bestimmt.




Abbildung 42: Beispiel des Parameters Fuzziness anhand zweier Trapez-Zugehörigkeitsfunktionen

Um den Verlauf beider angrenzender Funktionen festzulegen, wurde ein Designparameter eingeführt: Fuzziness. Die Fuzziness bestimmt den Verlauf der beiden an einem Schnittpunkt angrenzenden Zugehörigkeitsfunktionen. Der Schnittpunkt wurde dabei aus den Daten gelernt. Sie besitzt den normierten Wertebereich von  $[0,1]$  und repräsentiert die enthaltene Fuzziness. Ein Wert von „0“ repräsentiert dabei keine Fuzziness, was den Spezialfall der booleschen Aussagenlogik, also eine Trennung in zwei scharfe Zugehörigkeitsfunktionen in Form von Rechtecken, darstellt. Ein Wert von „1“ repräsentiert die maximale Unschärfe, was durch die geringste mögliche Steigung der Zugehörigkeitsfunktionen realisiert wird. Mit dem Wert „1“ verlaufen die Zugehörigkeitsfunktionen entlang der Schnittstelle mit der minimal möglichen Steigung, welche durch die Lage der übernächsten Zugehörigkeitsfunktionen begrenzt wird. Somit entstehen sanftere Übergänge zwischen den Zugehörigkeitsfunktionen, aber die enthaltene Unschärfe steigt.

Mit Hilfe dieser Festlegungen lassen sich beispielsweise fünf Fuzzymengen anhand der Daten festlegen, um das Signal des Lenkwinkels für eine Fahrmanöverprädiktion des Fahrstreifenwechsels nach links zu fuzzifizieren (vgl. Abbildung 41 unten).

#### 5.1.2. Lernen der Fahrerhaltenssequenzen

Nach der Bestimmung der Lage aller Zugehörigkeitsfunktionen von allen Eingangsgrößen werden im nächsten Schritt die Eingangsgrößen analog zu einem Fuzzy Logik System mit Regeln miteinander verknüpft. Eine Regel besteht dabei aus Prämisse (WENN-Teil) und Konklusion (DANN-Teil). Da das Ziel dieses Arbeitsschrittes die Klassifizierung der Fahrmanöver ist, ist die Konklusion das entsprechende Fahrmanöver. Somit kann die  $k$ -te Regel  $r_k(t)$  als Menge/Verknüpfung der enthaltenen  $n$  Prämissen  $s_{k,n}(t)$  aufgestellt werden:

$$r_k(t) = \{s_{k,1}(t), s_{k,2}(t), \dots, s_{k,n}(t)\}$$

Im ersten Schritt wird eine Matrix aufgebaut, die alle möglichen Regeln enthält. Die Dimension der Matrix entspricht dabei der Anzahl der Eingangsgrößen und die Länge entlang jeder Dimension entspricht der Anzahl der Zugehörigkeitsfunktionen der entsprechenden Eingangsgröße.

Nehmen wir als Beispiel drei Eingangsgrößen mit jeweils fünf Zugehörigkeitsfunktionen, ergibt dieses eine  $5 \times 5 \times 5$  Matrix mit 625 möglichen Kombinationen. Eine weitere Eingangsgröße mit fünf Zugehörigkeitsfunktionen würde die Matrix auf 3125 mögliche Kombinationen anwachsen lassen. Da die Komplexität sehr stark mit der Anzahl der Eingangsgrößen und Zugehörigkeitsfunktionen wächst, ist eine sparsame Wahl für eine echtzeitfähige Anwendung unumgänglich.

Eine weitere Reduzierung ist möglich, wenn die Daten der Probandenstudie verwendet werden. Daher wird die mögliche Anzahl an Regeln, auf die Anzahl reduziert, welche in den Daten der Studie vorlagen und die nicht aufgetretenen Kombinationen entfernt. Dadurch reduziert sich die Regelbasis deutlich und es müssen weniger Regeln in jedem Rechenschritt ausgewertet werden.

Zur Aggregation der Regeln können, wie im Kapitel 2.4 beschrieben, verschiedene Operatoren verwendet werden. In dieser Arbeit wird die Multiplikation eingesetzt. Somit ergibt sich für den Aggregationswert der  $k$ -ten Regel  $r_k(t)$ :

$$\mu_{agg,k}(t) = s_{k,1}(t) * s_{k,2}(t) * \dots * s_{k,n}(t)$$

Die Fahrmanöver finden auf dem taktischen Level der Fahrzeugführung statt und dauern somit einige, wenige Sekunden an. Ein Fahrmanöver kann als sequentielle Folge von Handlungen eines Fahrers betrachtet werden (Langer 2016). Da die Inferenz der Fuzzy Logik eine nichtlineare Abbildung der Eingangsgrößen auf die Ausgangswerte unter Nutzung eines statischen Kennfeldes darstellt, ist die Modellierung von zeitlichem Verhalten nicht direkt möglich. Aufgrund der zeitlichen Eigenschaft des Fahrerverhaltens, welches durch die Daten repräsentiert wird, wurde eine Erweiterung der Fuzzy Logik vorgenommen.

Es werden nicht die jeweils stärkste Regel ausgewertet und danach die aktivierten Fuzzy-Regeln akkumuliert, sondern aus der Aktivierung der jeweils stärksten Regel über die Zeit eines Fahrmanövers wird eine Kette gebildet. Eine von  $m$  Fahrerverhaltenssequenzen ( $V_m$ ) setzt sich dabei aus der zeitlichen Abfolge von  $l$  Zuständen ( $z_{m,l}$ ) zusammen:

$$V_m = \{z_{m,1}, z_{m,2}, \dots, z_{m,l}\}$$

Somit kann ein Fahrmanöver als Menge der Mächtigkeit  $l$  von  $m$  aktivierten Regeln dargestellt werden, welche in zeitlicher Abfolge gemäß dem jeweiligen Aggregationswert  $\mu_{agg,k}$  aktiviert werden:

$$R_m = \{r_{m,1}, r_{m,2}, \dots, r_{m,l}\}$$

Dabei erhält die Menge  $R_1$  die Regeln mit dem jeweils höchsten Aggregationswert zum jeweiligen Zeitpunkt, die Menge  $R_2$  dementsprechend die Regeln mit dem zweithöchsten Aggregationswert fortlaufend bis  $R_m$ . Da wir bei der Manöverausführung von Zeitverläufen sprechen, in denen sich die Signalwerte ändern können, ist der Aggregationswert  $\mu_{agg,k}(t)$  über einen Zeitraum  $t_d$  nicht konstant. Somit wird darüber hinaus ein mittlerer Aggregationswert  $\bar{\mu}_{agg,k}$  für jede Regel berechnet und in der jeweiligen Fahrerverhaltenssequenz  $V_m$  gespeichert. Da auch der Zeitraum  $t_d$  der Aktivierung des Zustandes  $z_{k,i}$  von Interesse ist, werden die Werte  $t_{k,i}$  ebenfalls betrachtet und mit dem jeweiligen Zustand  $z_{k,i}$  verknüpft. Ein Zustand  $z_{k,i}$  beinhaltet folgende relevanten Werte:

$$z_{k,i} = \{r_{k,i}, \bar{\mu}_{agg,k,i}, t_{k,i}\}$$

Betrachtet man den Verlauf eines Fahrstreifenwechsels über die Zeit, werden zu unterschiedlichen Zeitpunkten verschiedene Regeln den höchsten Aggregationswert erhalten. Ordnet man jedem Zeitschritt dabei die Regel mit dem höchsten Aggregationswert zu, so kann der Zeitverlauf der Aktivierung verschiedener Regeln über der Zeit als gerichteter Graph dargestellt werden:




Abbildung 43: Schematische Darstellung einer Fahrerhaltenssequenz

Im Unterschied zu Bauer (2011) werden hier aber nicht nur die Regeln mit dem höchsten Aggregationswert zu einem Zustandsautomaten zusammengefasst und ausgewertet, sondern alle Sequenzen berücksichtigt, denn jede Sequenz ist eine spezielle Ausprägung des Fahrmanövers, welches inter- und intraindividuelle Unterschiede der Manöverausrührung beinhaltet. Daher sollte jede Sequenz bei der Berechnung berücksichtigt werden, um eine große Variabilität in der Manöverausrührung detektieren zu können. Dadurch steigt der notwendige Rechenaufwand, welcher durch Anpassungen, beschrieben im Kapitel 5.1.3, adressiert wird. Jede Sequenz unterscheidet sich durch die auftretenden Zustände, die Reihenfolge der Zustände, den Aktivierungszeitraum jedes Zustandes und dem mittleren Aggregationswert.

Durch das Lernen der Sequenzen mit den Daten der Probandenstudie entsteht je ausgeführtem Fahrmanöver eine Sequenz. Diese Sequenzen werden für das spätere Klassifizieren des Fahrmanövers in einer Fahrmanöverdatenbank abgespeichert. Jede Manöverdatenbank enthält dabei alle Fahrmanöversequenzen eines bestimmten Fahrmanövers, wie zum Beispiel den Fahrstreifenwechsel nach links. Betrachten wir einen beispielhaften Ablauf eines Fahrstreifenwechsels (Abbildung 44):




Abbildung 44: Beispiel eines Fahrstreifenwechsels nach links mit Lenkwinkel (oben), TLC (Mitte) und kumuliertem Blinksignal (unten) sowie der entsprechenden Zustandskette.

In der Abbildung sind drei charakteristische Signale zur Beschreibung eines Fahrstreifenwechsels, die Grenzen der Fuzzymengen sowie die dazugehörige Verhaltenssequenz im Zeitraum vor dem Berühren der Fahrstreifenmarkierung ( $t = 0$  s) bei einem Fahrstreifenwechsel nach links dargestellt.

Der Fahrer fährt zum Zeitpunkt  $t = -2,5s$  mit einem Lenkwinkel nahe  $0^\circ$  annähernd parallel zur linken Fahrstreifenmarkierung mit  $TLC > 2s$  und deaktiviertem Blinker geradeaus. Das Verhalten ist durch den Zustand (131) der Verhaltenssequenz beschrieben. Bei  $t = -1,8s$  aktiviert der Fahrer den Blinker nach links und das kumulierte Blinkersignal  $bl_\Sigma$  steigt an, ohne jedoch zu diesem Zeitpunkt eine benachbarte Zugehörigkeitsfunktion zu aktivieren. Zum Zeitpunkt  $t = -1,6s$  dreht der Fahrer das Lenkrad so stark nach links, dass der Lenkwinkel  $\delta = 3,0^\circ$  übersteigt. Somit wird die zweite Fuzzymenge des Lenkwinkels aktiv und ein neuer Zustand in der Verhaltenssequenz wird aktiviert (231). Zum Zeitpunkt  $t = -1,4s$  erreicht das kumulierte Blinkersignal den Wert  $bl_\Sigma = 0,1s$  und Zustand (232) wird aktiv. Bei  $t = -1,25s$  sinkt die TLC unter  $1,7s$ , der Lenkwinkel steigt über  $7,0^\circ$  und Zustand (322) ist aktiv. Zum Zeitpunkt  $t = -0,75s$  hat der Fahrer das Lenkrad auf einen Lenkwinkel von über  $\delta = 12,0^\circ$  gedreht und Zustand (422) ist aktiv. Nachdem bei  $t = -0,7s$  die TLC auf einen Wert unter  $0,7s$  fällt wird Zustand (412) aktiviert. Bei  $t = -0,4s$  erreicht das kumulierte Blinkersignal den Wert  $bl_\Sigma = 0,3s$  und Zustand (413) ist aktiv. Bis zum Berühren der Fahrstreifenmarkierung ( $t = 0s$ ) treten keine weiteren Änderungen in den Aktivierungsfunktionen auf, wodurch die Sequenz vollständig ist.

Die Zustandssequenzen enthalten die Aktivierung und den zeitlichen Verlauf der Zugehörigkeitsfunktionen der Signale bei der Vorbereitung und Durchführung des zu erkennenden Fahrmanövers und modellieren somit das menschliche Verhalten bei der Fahrmanöverausführung.

### 5.1.3. Aufbau des Zustandsautomaten

Da die Berücksichtigung jeder Fahrerhaltenssequenz sehr rechenaufwändig ist, wird ein Verfahren zur Reduktion der Rechenzeit implementiert. Dazu wird aus allen Fahrerhaltenssequenzen ein Zustandsautomat erzeugt.




Abbildung 45: Beispiel drei verschiedener Fahrerhaltenssequenzen

Am Beispiel von drei Fahrerhaltenssequenzen in Abbildung 45 ist die Synthese des Zustandsautomaten ersichtlich. Die drei Sequenzen werden hinsichtlich der enthaltenen Zustände analysiert. Im nächsten Schritt werden die Transitionen betrachtet und aus den gewonnenen Informationen aus vorliegenden Zuständen und Transitionen wird dann ein Zustandsautomat generiert.




Abbildung 46: Beispiel eines Zustandsautomaten generiert aus den Fahrerhaltenssequenzen in Abbildung 45

Dieser Zustandsautomat beinhaltet alle Zustände und mögliche Transitionen, welche in den zugrunde gelegten Sequenzen aufgetreten sind. In der Abbildung 46 sind die Anfangszustände grau und der Endzustand gestreift markiert. Dieses ist für die Einsparung von Rechenzeit relevant. Je nach Strategie können verschiedene Varianten der Aktivierung und Deaktivierung eingesetzt werden, um die inter- und intraindividuellen Unterschiede und die begrenzte Anzahl der Trainingsdaten zu berücksichtigen. Der Zustandsautomat entscheidet, ob für das jeweilige Fahrmanöver die Sequenzen analysiert werden, oder nicht. Eine Berechnung erfolgt nur, falls der Zustandsautomat aktiviert ist. Wählt man dabei eine konservative Aktivierungsstrategie, kann es sein, dass Fahrmanöver, welche den Trainingsdaten ähneln, als verschieden eingestuft werden und somit keine korrekte Klassifizierung erfolgen kann. Wird eine zu liberale Strategie verwendet, ist der Zustandsautomat im schlimmsten Fall ständig aktiviert und eine Einsparung von Rechenzeit wird verfehlt.

Eine Aktivierung erfolgt, sobald einer der markierten Startzustände aktiviert wurde. Der Zustandsautomat bleibt solange aktiviert, wie nicht mehr als eine vorgegebene Anzahl an nicht vorhandenen Transitionen zu vorhandenen Zuständen benutzt werden. Er wird deaktiviert, sobald mehr als die erlaubte Menge an unbekannten Transitionen ausgeführt werden oder ein Zustand, welcher als Endzustand markiert ist, erreicht wird. Die Anzahl der maximal erlaubten Menge nicht enthaltener Transitionen ist ein weiterer Algorithmusdesignparameter.

#### 5.1.4. Edit Distance Metrik

Wie im Kapitel 2.4 erläutert, stellt die Edit Distance ein Distanzmaß zum Vergleich von Zeichenketten und Mustererkennung dar. In Abbildung 47 ist ein Beispiel von zwei gelernten Fahrmanöversequenzen dargestellt:




Abbildung 47: Beispiel zweier ähnlicher Fahrerhaltenssequenzen

Die Nummerierung der Zustände erfolgt gemäß der aktivierten Regel. Fängt die erste Sequenz mit  $z_{31}$  an, bedeutet das, dass in diesem Zustand die Regel mit der dritten Fuzzymenge des ersten Eingangssignals und die erste Fuzzymenge des zweiten Eingangssignals den maximalen Aggregationswert erreichen. In der oberen Sequenz folgt daraufhin der Zustand  $z_{21}$ , was bedeutet, dass die Regel mit der zweiten Fuzzymenge des ersten Eingangssignals und der ersten Fuzzymenge des zweiten Eingangssignals den maximalen Aggregationswert erreichen. In der unteren Sequenz wird Zustand  $z_{32}$  aktiv, was zum Beispiel durch interindividuelle Unterschiede in der Manöverausführung entsteht, falls Sequenz eins und zwei von verschiedenen Fahrern gelernt wurden. Durch die hohe Anzahl an möglichen Zuständen werden bei drei Eingangssignalen mit je fünf Fuzzyzugehörigkeitsfunktionen 125 mögliche Zustände erreicht. Durch die zusätzlich gespeicherten Werte des mittleren Aggregationswertes  $\bar{\mu}_{agg} \in [0,1]$ , zur Vereinfachung als zehnstufige Variable betrachtet, und der jeweiligen Aktivierungszeit  $t_a \in [0, t_{max}]$ , bei einer Abtastrate von  $10Hz$  und einer maximalen Manöverzeit von  $t_{max} = 5s$ , ergeben sich rechnerisch bis zu 1300 verschiedene Sequenzen. Daher ist es sehr unwahrscheinlich, in einem begrenzten Trainingsdatensatz durch das Auftreten der menschlichen inter- und intraindividuellen Abweichungen, zwei identische Sequenzen zu lernen.






Abbildung 48: Beispiel einer Fahrerhaltenssequenz zum Vergleich mit Abbildung 47

Es ist sehr wahrscheinlich, dass eine Sequenz des aktuellen Fahrerhaltens gemessen wird, welche nicht in der Manöverdatenbank vorliegt (siehe Abbildung 48). Hieran kann man gut erkennen, dass falls nur identische Sequenzen gesucht werden und in diesem Fall keine Übereinstimmung gefunden wird, die aufgetretene Sequenz nicht zur obigen Manöverdatenbank als zugehörig klassifiziert wird. Wie bereits im Kapitel 2.4 erwähnt, ist die Edit Distance jedoch in der Lage, Ähnlichkeiten durch Kombinationen zu identifizieren.

Im aufgeführten Beispiel unterscheiden sich die beiden Sequenzen der Datenbank nur durch einen Zustand, welcher durch eine Operation der Edit Distance egalisiert werden kann. Somit sind sich die beiden Sequenzen sehr ähnlich, was bei der Zugehörigkeit zum selben Fahrmanöver auch zu erwarten ist. Auch die dritte Kette des aktuellen Fahrerhaltens lässt sich durch jeweils zwei bzw. eine Transformation durch Ersetzen in die vorhandenen Sequenzen transformieren. Daher liegt es nahe, dass das Fahrerverhalten dem gelernten und gespeicherten Fahrerverhalten sehr ähnelt und dem Manöver als zugehörig klassifiziert werden sollte.

Zusammenfassend ist der Ablauf der Inferenz des Algorithmus der, dass die aktuelle vom Fahrer produzierte Zustandssequenz mit der im Training des Algorithmus mit Daten der Probandenstudie verglichen wird. Diese gelernten Zustandssequenzen sind durch die kontrollierten Bedingungen der Probandenstudie für das jeweilige Fahrerverhalten bei der Fahrmanöverausrührung repräsentativ. Durch den Vergleich des bis dahin unbekannten Fahrerhaltens mit gelernten Daten kann dann mit einer gewissen Unsicherheit durch das Ähnlichkeitsmaß auf das wahrscheinlichste Fahrmanöver, zu dem das aktuelle Fahrerverhalten passt, geschlossen werden.

### Kontinuierliches Abstandsmaß

Für einen späteren echtzeitfähigen Vergleich von Sequenzen ist eine kontinuierliche Berechnung der Edit Distance notwendig. Chua et al. (2011) modifizieren die Levenshtein-Distanz dahingehend, dass nicht nur Sequenzen fester Längen, sondern auch fließende Sequenzen, wie sie bei der Ausführung von Fahrmanövern entstehen, verglichen werden können. Durch folgende Anpassung in der Rekurrenzmatrix, bei der die erste Zeile mit Nullen gefüllt wird, die zu erkennende Sequenz zeilenweise und die gelernten Sequenzen der Datenbank spaltenweise aufgetragen werden, ist eine kontinuierliche Auswertung möglich, da jeder neue Zustand der aktuellen Sequenz als potentieller Anfang des Fahrmanövers betrachtet werden kann.

### Kosten für die Operationen

Ein wesentlicher Punkt der Anpassung der Edit Distance zur Nutzung zur Fahrmanöverprädiktion ist die Festlegung der Kosten der Operationen. Durch die Analyse der Probandenstudie treten bei einem Fahrmanöver gewisse Zustände häufiger auf, als bei anderen Fahrmanövern. Beispielsweise ist die Annäherung an die Fahrstreifenmarkierung mit einem entsprechenden Lenkradwinkel typisch für einen Fahrstreifenwechsel, wodurch dieser Zustand bei vielen Sequenzen des Fahrstreifenwechsels enthalten sein wird, jedoch sehr selten bei einem Anhaltenmanöver. Dieses Wissen soll zur Anpassung der Kosten benutzt werden. Die relative Häufigkeit und die Kosten sollen sich dabei antiproportional verhalten, d.h., je häufiger ein gewisser Zustand bei einem Fahrmanöver aufgetreten und in der Manöverdatenbank vorhanden ist, desto günstiger sollen die Kosten für das „Einfügen“ bzw. „Löschen“ dieses Zustandes bei der Berechnung der Edit Distance sein. Ein sehr selten vorkommender Zustand erhält sehr hohe Kosten beim Hinzufügen je Rechenschritt. Zur genauen Berechnung wird die relative Häufigkeit jedes

einzelnen Zustandes aus allen Sequenzen einer Fahrmanöverdatenbank berechnet und der Kehrwert davon auf ein Intervall zwischen  $[1,2]$  abgebildet. Dieses hat die gleiche Spannweite wie das Einheitsintervall, besitzt jedoch den Vorteil, dass die Kosten für das Hinzufügen niemals Null werden können. Das Einfügen des häufigsten Zustandes erhält somit die Kosten „eins“ und ein nicht vorkommender Zustand würde beim Einfügen den Kostenwert „zwei“ erhalten. Die Operation „Ersetzen“ soll mit geringeren Kosten versehen werden, als das Entfernen und folgende Hinzufügen eines Zustandes. Würde diese Annahme nicht gelten, könnten aus einer Sequenz mit geringen Kosten alle Zustände entfernt und komplett mit anderen Zuständen besetzt werden, was einer zielgerichteten Berechnung eines Abstandsmaßes widersprechen würde. Bei der Berechnung der Kosten des Einfügens wird die Reihenfolge der Zustände analysiert und berücksichtigt. Das Austauschen von Zuständen, welche häufiger in Folge auftreten, erhalten geringere Kosten, als das Ersetzen mit einem Zustand, welcher sehr selten bis gar nicht in der Folge der vorausgehenden Zustände auftritt. Diese Information wird durch die Analyse der aufgetretenen Zustandstransitionen erhalten.

Die relative Häufigkeit der Transitionen wird als Maß für die Kosten für alle aufgetretenen Zustandskombinationen der gelernten Fahrmanöversequenzen betrachtet und wird für die Operation „Ersetzen“ auf das Einheitsintervall  $[0,1]$  abgebildet. Somit erhält das Ersetzen eines Zustandes durch einen anderen, welcher häufig nach dem Vorgänger des zu ersetzenden Zustandes in den Sequenzen der Fahrmanöverdatenbank vorhanden ist, geringe Kosten und das Ersetzen mit Zuständen, welche seltene Transitionen erzeugen, führt zu hohen Kosten dieser Operation. Unbekannte Transitionen erhalten den Kostenwert von „zwei“. Darüber hinaus werden die Transitionen, wie soeben beschrieben, nicht nur ungerichtet betrachtet, sondern auch die Reihenfolge spielt eine große Rolle in der Prädiktion von Fahrmanövern.

Nicht nur das Auftreten gewisser Zustände deutet auf ein bestimmtes Fahrmanöver hin, auch aus der Reihenfolge des Auftretens lassen sich Informationen gewinnen, um auf ein zukünftiges Fahrmanöver zu schließen. Zum Beispiel tritt Zustand  $z_2$  sehr häufig nach Zustand  $z_1$ , wie in Abbildung 49 dargestellt, aber nie vor  $z_1$  auf.




Abbildung 49: Beispiel zur Reihenfolge der Transitionen für die Edit Distance

Der Zustand  $z_3$  tritt in der mittleren Sequenz in Abbildung 49 nach Zustand  $z_1$  auf. Durch das Ersetzen des Zustandes  $z_3$  durch Zustand  $z_2$ , mit Hilfe der Operation „Ersetzen“, wird die Ähnlichkeit zur oberen Sequenz erzeugt. Dieses ist mit geringen Kosten belegt, da Zustand  $z_2$  sehr häufig in den Daten nach Zustand  $z_1$  auftritt. Damit sind die oberen beiden Sequenzen sehr ähnlich. Würde bei der unteren Sequenz in Abbildung 49 Zustand  $z_3$  durch Zustand  $z_2$  ersetzt werden, führt eine ungerichtete Betrachtung der Transitionen zu denselben Kosten. Da der Zustand  $z_2$  nie vor Zustand  $z_1$  in den gelernten Sequenzen aufgetreten ist, entstehen durch die gerichtete Betrachtung der Transitionen hohe Kosten, was zur besseren Berücksichtigung der Trainingsdaten führt.

---

## Berücksichtigung der Zeitdauer und Normierung

Weiterhin wird zu den Zuständen, wie bereits beschrieben, die Zeitdauer der Aktivierung der jeweiligen Zustände  $t_a$  gespeichert. Somit kann ein kurzer Lenkimpuls zur Stabilisierung des Fahrzeuges innerhalb des Fahrstreifens beim Geradeausfahren, vom Beginn eines Fahrstreifenwechsels durch einen kontinuierlichen Lenkeinschlag unterschieden werden. Dieses wird bei der Operation „Ersetzen“ zu den bisherigen Parametern ebenfalls berücksichtigt. Durch die Addition des Betrages der Zeitdifferenz des zu ersetzenden Zustandes mit dem neuen Zustand auf den Wert des Abstandsmaßes wird dieser Umstand berücksichtigt. Ebenfalls bei den Operationen „Einfügen“ und „Entfernen“ wird der Betrag des Wertes der Zeitdifferenz addiert. Somit wird bei allen Operationen die Zeitdauer der beiden betrachteten Zustände berücksichtigt und eine hohe Zeitdifferenz mit hohen Kosten belegt.

Beim Training der Zustandssequenzen treten durch das inter- und intraindividuell unterschiedliche Verhalten der Fahrer verschieden lange Sequenzen mit unterschiedlicher Anzahl von Zuständen auf. Um diesen Umstand bei der Berechnung zu berücksichtigen, wird der berechnete Wert des Abstandsmaßes auf die Länge der Sequenzen normiert. Die Summe des Hinzufügens jedes Zustandes zu jeder Sequenz ergibt einen Wert, welcher individuell für jede Sequenz und nur abhängig von der Sequenz selber ist. Dieser Wert wird für die Normierung verwendet, indem der berechnete Abstandswert am Ende aller Operationen durch diesen sequenzindividuellen Wert geteilt wird. Somit ist der Vergleich von einer Sequenz mit zwei verschiedenen langen gelernten Sequenzen ohne Bias möglich.

### Sekundärsequenzen

Bei der bisherigen Beschreibung der Edit Distance wurde davon ausgegangen, dass immer genau eine Sequenz mit den gelernten Daten der Probandenstudie verglichen wird. Diese Sequenz ergibt sich durch die Berücksichtigung des höchsten Aggregationswertes der aktivierten Zustände. Nun können durch die individuell verschiedenen Ausführungen kleine Differenzen zu verschiedenen Sequenzen führen. Eine Betrachtung von sog. Sekundärsequenzen soll diesen Umstand adressieren.

Eine Sekundärsequenz entsteht, analog zur Primärsequenz, indem die Zustände mit dem jeweils zweithöchsten Aggregationswert zu einer Sequenz aufgereiht werden. Der Vorteil ist, dass dadurch das jeweilige Fahrerverhalten besser repräsentiert werden kann, da mehr Informationen ausgewertet werden. Der Nachteil ist jedoch, dass in jedem Rechenschritt zwei, anstelle nur einer Sequenz mit den Trainingsdaten verglichen werden müssen, was zur doppelten Rechenzeit führt. Um die Abstandswerte beider Sequenzen  $d_1$  und  $d_2$  zu einem Gesamtabstand  $d_\Sigma$  zu vereinen wird die Methode der Defuzzifizierung mit Hilfe des Flächenschwerpunktes adaptiert. Die Abstandswerte werden dabei mit den durchschnittlichen Aggregationswerten  $\bar{\mu}_1$  und  $\bar{\mu}_2$  beider Sequenzen normiert. Es ergibt sich  $d_\Sigma$  zu:

$$d_\Sigma = \frac{\bar{\mu}_1 * d_1 + \bar{\mu}_2 * d_2}{\bar{\mu}_1 + \bar{\mu}_2}.$$

#### 5.1.5. K-Nearest-Neighbor

Nachdem aus den Versuchsdaten die Fahrmanöversequenzen nach dem Verfahren im Kapitel 5.1.2 gelernt und abgespeichert wurden, ist im weiteren Schritt eine Inferenz zur Klassifizierung einer unbekannten Sequenz notwendig. Nearest-Neighbor Verfahren bieten aufgrund der im Kapitel 2.4 aufgezeigten Vorteile die Chance, eine sinnvolle Inferenzmethode darzustellen. Zur echtzeitfähigen Klassifizierung von Fahrmanövern muss das aktuelle Fahrerverhalten in der gleichen Art und Weise fuzzifiziert werden, um mit den gelernten und gespeicherten Sequenzen verglichen werden zu können. Die Fuzzifizierung ist mit dem Verfahren aus Kapitel 5.1.2 möglich, da die Grenzen und der Verlauf der Fuzzy-Zugehörigkeitsfunktionen eindeutig feststehen und auch Aggregationswerte und Zeitdauern der Aktivierung der Zustände in Echtzeit aufgenommen werden können.

Das k-NN Verfahren ermöglicht den Einsatz der Edit Distance zum Vergleich der aktuell auftretenden Sequenz eines unbekannten Fahrerverhaltens mit den trainierten und abgespeicherten Sequenzen in der Manöverdatenbank. Allerdings stellt sich ein aktuelles Fahrerverhalten als quasi endlose Verkettung von Zuständen dar. Somit ist eine Variante der kontinuierlichen Berechnung notwendig, was im Kapitel 5.1.4 genauer beschrieben wurde.

#### 5.1.6. Wahrscheinlichkeit und Zeithorizont

Durch die Berechnung entsteht für eine Sequenz ein Vektor an Abstandsmaßen, welcher die Einzelabstände zu jeder gespeicherten Sequenz beinhaltet. Dabei können die Werte sehr verschieden sein. Durch hohe interindividuelle Verschiedenheiten in der Fahrzeugführung würde eine Mittelung der Werte zu einer großen Ungenauigkeit und somit zu einer schlechten Gesamtleistung des Systems führen. Besteht ein Trainingsdatensatz aus einer ungleichen Verteilung von 90% sportlich ausgeführten Fahrmanövern eines Typs und 10% defensiv ausgeführten Fahrmanövern, würde bei einem Vergleich mit einem defensiv gefahrenen Manöver mit dem Trainingsdatensatz eine geringe Übereinstimmung erreicht werden, jedoch bei der Ausführung mit einem sportlichen Manöver eine hohe Übereinstimmung. Um diesen Umstand zu adressieren wird ein gewichtetes Mittel verwendet. Dieses ist vergleichbar mit dem Elo-Wertungssystem nach dem Erfinder Arpad Elo, welches im Schach-Sport 1960 eingeführt wurde. Es wird mittlerweile in weiteren Sportarten, u.a. im Tischtennis oder Brettspiel Go eingesetzt, um die Leistung verschiedener Sportler vergleichbar zu gestalten, ohne dass diese in einem Wettkampf gegenübergestellt haben müssen. Auch zur vergleichenden Bewertung von Fußballmannschaften wird das Verfahren von Schiefler (2015) auf der Internetseite [www.clubelo.com](http://www.clubelo.com) angewendet. Die Berechnung des Gesamtabstandes  $d_\Sigma$  ergibt sich dabei zu:

$$d_\Sigma = \frac{\sum_{k=0}^{n_m} a_0 q^k d_k}{\sum_{k=0}^{n_m} a_0 q^k}$$

Dabei beschreibt der Term  $a_0 q^k$  das  $k$ -te Gewicht  $a_k = a_0 q^k, k = 1 \dots (n - 1)$  aller  $n$  Vergleichswerte mit einem Startwert  $a_0$  und dem Quotient  $q$  zweier aufeinanderfolgender Werte. Für  $|q| < 1$  konvergiert  $\sum_{k=0}^{\infty} a_0 q^k$  gegen  $\frac{a_0}{1-q}$ . Daher führt ein Wert für  $q$  nahe „0“ zu einer anteilmäßig höheren Berücksichtigung hoher Werte, wohingegen der Fall  $q = 1$  das arithmetische Mittel darstellt, in dem alle Werte zu gleichen Anteilen berücksichtigt werden.

Die Wahl eines sinnvollen Wertes für  $q$  ist nicht direkt ersichtlich. Dieser Parameter ist somit ein weiterer Designparameter, welcher im folgenden Kapitel, in Verbindung mit weiteren Designparametern zur Erreichung einer bestmöglichen Detektionsleistung optimiert wird.

Nach der Berechnung des Vektors der Abstandsmaße und eines gewichteten Gesamtabstandes soll im Folgenden diese Information genutzt werden, um eine Wahrscheinlichkeit zu berechnen, ob das aktuell ausgeführte Manöver zu einer Trainingsdatenbank gehört. Sobald der Abstand einer Sequenz sehr gering zur trainierten Manöverdatenbank ist, ist die Wahrscheinlichkeit sehr hoch, dass das aktuell ausgeführte Manöver den Trainingsdaten entspricht. Und umgekehrt, ist das Abstandsmaß einer Sequenz zur entsprechenden Datenbank sehr groß, ist die Wahrscheinlichkeit klein, dass es sich um das gesuchte Manöver handelt. Daher korrelieren die Wahrscheinlichkeit  $p$  und der Gesamtabstand  $d_\Sigma$  negativ. Die Berechnung der Manöverwahrscheinlichkeit wird aus dem Gesamtabstand mit Hilfe einer direkten Zuordnung in Form einer Abbildung realisiert. Die Verwendung der laplaceschen Wahrscheinlichkeit (Laplace 1951) ist nicht möglich, da dafür exakte Repräsentationen des menschlichen Verhaltens bei der Fahrzeugführung, des Fahrzeuges und der Umgebung erforderlich sind, um die notwendigen a-priori Wahrscheinlichkeiten zu bestimmen. Die Wahrscheinlichkeit wird daher mit Hilfe des Häufigkeitsprinzips unter Nutzung der relativen Häufigkeiten angenähert.

Ein genauer Zusammenhang zwischen Wahrscheinlichkeit  $p$  und Gesamtabstand  $d_{\Sigma}$  kann somit unter Zuhilfenahme der Daten der Probandenstudie realisiert werden. Es wird die Einteilung der Prädiktion in diskrete Erkennungsintervalle verwendet. Unter Zuhilfenahme einer guten Aktivierungsstrategie des Zustandsautomaten kann die statistische Wahrscheinlichkeit ausreichend genau berechnet werden. Dazu werden die Aktivierungen des zugehörigen Zustandsautomaten (vgl. Kapitel 5.1.3) anhand der Trainingsdaten ermittelt und zu jeder Aktivierung wird vermerkt, ob innerhalb dieser Aktivierung eine Manövermarkierung vorzufinden ist, also das entsprechende Fahrmanöver ausgeführt wurde.

Weiterhin wird innerhalb jedes Aktivierungszeitraums  $i$  der minimal erreichte Edit Distance Wert  $d_{min,i}$  berechnet und vermerkt. Der minimal erreichbare Wert für  $d_{\Sigma}$  berechnet sich aus dem Minimum aller Einzelwerte:  $d_{min} = \min(d_{min,i})$  und der Maximalwert für  $d_{\Sigma}$  aus dem Maximum der minimal aufgetretenen Einzelwerte  $d_{max} = \max(d_{min,i})$ . Hier wird der Maximalwert der minimal erreichbaren Werte  $d_{min,i}$  und nicht ein maximal erreichbarer Wert betrachtet, da nur der minimale Wert charakteristisch für die Richtig- oder Falscherkennung des Fahrmanövers ist. Zum Beispiel ergeben sich sowohl bei einer richtigen Aktivierung des Zustandsautomaten vor einem Fahrmanöver als auch bei einer falschen Aktivierung des Zustandsautomaten zu Beginn ähnlich hohe Werte für  $d$  und eine Unterscheidung zwischen Richtig- und Falscherkennungen wäre nur schwer möglich, wenn nicht sogar komplett unmöglich. Somit ergibt sich der Definitionsbereich für  $d_{\Sigma}$  zu:  $d_{\Sigma} = [d_{min}, d_{max}]$ .

Mit Hilfe der Anzahl der Aktivierungen, in denen eine Manövermarkierung liegt  $n_{pos}(d_{\Sigma})$ , dieses entspricht der Anzahl der Richtigerkennungen des Systems und der Anzahl der Falscherkennungen  $n_{neg}(d_{\Sigma})$ , also Aktivierungen in deren Zeitraum keine Manövermarkierung besteht, kann die Wahrscheinlichkeit in Form der Häufigkeit mit Hilfe der folgenden Gleichung berechnet werden:

$$p(d_{\Sigma}) = \frac{n_{pos}(d_{\Sigma})}{n_{pos}(d_{\Sigma}) + n_{neg}(d_{\Sigma})}$$

Dieses wird in einer sinnvollen Schrittweite von 0,01 für alle  $d_{\Sigma}$  aus  $[d_{min}, d_{max}]$  berechnet und es ergibt sich eine Zuordnung von  $d_{\Sigma}$  auf  $p$ .




Abbildung 50: Zuordnung des Gesamtabstands  $d_{\Sigma}$  auf die Wahrscheinlichkeit  $p$

Mit Hilfe dieser Abbildung kann direkt aus einem ermittelten  $d_{\Sigma}$ , einer bis dahin unbekannten Sequenz, die Wahrscheinlichkeit berechnet werden, ob die Sequenz zum trainierten Fahrmanöver gehört.

Zwischen den gelernten Werten für  $d_{\Sigma}$  wird interpoliert, um eine kontinuierliche Zuordnung von  $d_{\Sigma}$  auf  $p$  zu erreichen.

Zur Berechnung des Zeithorizontes kann ebenfalls der Gesamtabstand  $d_{\Sigma}$  genutzt werden, da der Verlauf des Gesamtabstandes, von der Aktivierung des Zustandsautomaten bis zur Deaktivierung in Höhe des Manöverbeginns, überwiegend monoton fallend verläuft.




Abbildung 51: Zuordnung des Gesamtabstands  $d_{\Sigma}$  auf den Zeithorizont  $t_h$

Hierzu werden zu allen Abstandswerten  $d_{\Sigma}(t)$  die dazugehörigen Werte des Zeithorizonts  $t_h(t)$  bis zur jeweiligen Manövermarkierung aus den Trainingsdaten berechnet. Im nächsten Schritt werden die Werte nach  $d_{\Sigma}$  sortiert und mit dem gleitenden Durchschnitt, einem Tiefpass, gefiltert. Das Ergebnis ist vergleichbar mit der Berechnung der Manöverwahrscheinlichkeit und liefert eine Zuordnung von  $d_{\Sigma} \mapsto t_h$ . Diese Schätzung ist entgegen der Einfachheit relativ genau mit einer Standardabweichung, welche ca. 50% des Zeithorizontes entspricht.

#### 5.1.7. Designparameteroptimierung des Algorithmus

Da einige Stellen der Entwicklung des Algorithmus die Wahl von Parametern notwendig gemacht hat, wurden an den jeweiligen Stellen Parameter vorgesehen, die in diesem Schritt optimiert werden, um eine maximale Algorithmus Performance zu ermöglichen. Dieses wird mit Hilfe der Daten der Probandenstudie durchgeführt. Zusammenfassend sind folgende Parameter zu optimieren:

- Eingangssignale
- Anzahl der Fuzzymengen
- Fuzziness
- Schaltstrategie des Zustandsautomaten (Maximale Anzahl verbotener Transitionen)
- Gewichtung Edit Distance Operationen
- Gewichtung der Einzelabstände
- Ordnung des Algorithmus
- Maximaler Zeithorizont

## Iterative Optimierung der Designparameter

Zur Optimierung der Designparameter, entsprechend der vorgestellten Bewertungsmaßstäbe im Kapitel 2.4, wurde eine iterative Einflussanalyse durchgeführt. Dabei wurde jeder Designparameter, ausgehend von einer Grundkonfiguration aus Expertenwissen, einzeln gezielt variiert und die Performance des Algorithmus wurde berechnet und bewertet. Hierzu wurde eine Untermenge der vorhandenen Probandendaten verwendet, um den zeitlichen Aufwand zu reduzieren. Es wurden zufällig 10 Probanden aus dem Sample gezogen und davon jeweils 7 Probanden zum Training des Algorithmus in den verschiedenen Konfigurationen und 3 Datensätze zum Test und zur Berechnung der Bewertungsmaßstäbe verwendet. Die verwendeten Datensätze wurden aufgrund der Vergleichbarkeit beibehalten. Verwendete Eingangssignale für die Designparameteroptimierung waren der Lenkwinkel  $\delta$ , die Lenkwinkelgeschwindigkeit  $\dot{\delta}$ , die Gierrate  $\Psi$ , der laterale Abstand zur Fahrstreifenmarkierung  $d_{lat}$ , die Time-to-linecrossing zur Fahrstreifenmarkierung  $TLC$  und eine kumulierte Blinkdauer  $bl_{\Sigma}$ .

Tabelle 12: Variation der Designparameter des Algorithmus

Parameter	Beispielkonfiguration	Variationsweite
Eingangssignale	$\delta; d_{lat}; TLC$	$\{\delta; \dot{\delta}; \Psi; d_{lat}; TLC; bl_{\Sigma}\}$
Anzahl Fuzzymengen	4	$\{3;4;5;6;7\}$
Fuzziness	0,5	$\{0,1;0,3;0,5;0,7;0,9\}$
Anzahl verbotener Transitionen	2	$\{0;1;2;3\}$
Gewichtung Edit Distance	1:3:2	$\{0:1:0; 0:1:1; \dots 3:2:1; 3:1:2\}$
Gewichtung der Sequenzen $q$	0,9	$\{0; 0,2; 0,4; 0,6; 0,8; 1\}$
Ordnung des Algorithmus	2	$\{1,2\}$

## Eingangssignale

Die Optimierung der Eingangssignale bzw. die Auswahl der besten Signale für die Prädiktion eines Fahrstreifenwechsels ist nicht trivial. Kapitel 4.2 beschreibt die Thematik und im Kapitel 4.4 wird eine Auswahlmatrix entwickelt und präsentiert. Darüber hinaus ist jedoch auch das Zusammenwirken verschiedener Eingangssignale zu berücksichtigen. Da das Hinzufügen eines weiteren Signals zu einem bestehenden Algorithmus oftmals den Informationsgehalt steigert, aber auch immer Unschärfe und Unsicherheit inkorporiert, kann durch Hinzufügen eines Signals die Erkennungsleistung reduziert werden, da die neu entstandene Signal-to-Noise-Ratio (SNR) schlechter ausfällt als in der Konfiguration ohne das Signal. Daher bietet die Matrix aus Kapitel 4.4 einen sehr guten Anhalt, welche Signale für das entsprechende Fahrmanöver geeignet sind, jedoch muss die Kombination der Signale in einem weiteren Schritt getestet werden. Ein heuristisches Verfahren zur Identifikation der besten Menge an Eingangssignalen ist in Sylla (2015) und Dosi (2016) zu finden. Zusammenfassend haben sich zur Prädiktion des Fahrstreifenwechsels folgende Signale als am besten geeignet herausgestellt:

- Time-To-Linecrossing (TLC)
- Heading Winkel des Fahrzeuges relativ zur Fahrstreifenmarkierung
- Abstand des Fahrzeuges zur Fahrstreifenmarkierung
- Kumulierte Aktivierung des Blinkers

Dieses entspricht den Werten des Bewertungsmaßstabs aus Kapitel 4.4.

---

## Anzahl der Fuzzymengen

Die Anzahl der Fuzzymengen ist ein wesentlicher Parameter, da er zum einen direkt die Genauigkeit der Differenzierung der Eingangssignale unterscheidet, aber auf der anderen Seite die Rechenzeit bei einer hohen Anzahl stark negativ beeinflusst. Nach Adamy (2011) ist eine Fuzzifizierung von Signalen bis zu einer Menge von neun noch von einem menschlichen Maschinenbediener als natürlich interpretierbar einzustufen. Daher wurde die Anzahl der Mengen im ersten Schritt durch Expertenwissen festgelegt, im weiteren Verlauf jedoch auch durch eine Variation heuristisch optimiert.

Eine Anzahl von fünf Fuzzymengen je Eingangssignal hat dabei die beste Erkennungsleistung erzielt (vgl. Kapitel 5.1.1 und Sylla 2015).

## Fuzziness

Die Fuzziness beeinflusst den Verlauf der Zugehörigkeitsfunktionen zwischen den Fuzzymengen. Eine hohe Fuzziness beinhaltet dabei mehr Unschärfe, als eine geringere. Die Rechenzeit wird dadurch nicht beeinflusst. Ein Unterschied in der Auswertung ergibt sich jedoch nur, bei einer höheren Ordnung des Algorithmus als Eins. Die Ordnung definiert dabei, ob nur die Fuzzyregel mit dem höchsten Aggregationswert zum Aufbau einer Sequenz berücksichtigt wird (Ordnung gleich Eins), oder ob weitere Regeln (z.B. Drei) mit geringeren Aggregationswerten zum Aufbau weiterer Sequenzen (in diesem Beispiel Primär-, Sekundär und Tertiärsequenz) verwendet werden. In dieser Arbeit wird mit der Ordnung gleich Eins aus dem aktuellen Fahrerverhalten die Primärsequenz extrahiert und in der Folge verarbeitet.

Eine Fuzziness von 0,5 hat dabei die beste Erkennungsleistung hervorgebracht (vgl. auch Sylla 2015).

## Schaltstrategie des Zustandsautomaten (Maximale Anzahl verbotener Transitionen)

Durch die Veränderung der maximal zulässigen Transitionen kann das Deaktivierungsverhalten und somit die Aktivierungszeit beeinflusst werden. Wird dieser Wert zu klein gewählt und sind gleichzeitig wenige Trainingsdaten vorhanden, steigt die Wahrscheinlichkeit, Fahrmanöver nicht zu erkennen. Wird der Wert zu hoch gewählt, können zu viele Fehlerkennungen zugelassen werden und bei einer ständigen Aktivierung ist die Reduktion des Rechenaufwandes durch dieses Verfahren nicht mehr vorhanden. Dieser Wert beeinflusst somit die Performance bezüglich der Richtig- und Falscherkennungen. Dieser Parameter sollte im Zusammenhang mit der Wahl der Eingangssignale, der Menge der vorhandenen Trainingsdaten und der erwarteten Komplexität des zu erkennenden Fahrmanövers gewählt werden.

Das Zulassen von maximal 2 verbotenen Transitionen hat dabei die beste Erkennungsleistung erzielt (vgl. auch Sylla 2015).

## Kosten Edit Distance Operationen

Die Veränderung der Kosten der Edit Distance Operation beeinflusst die Rechenzeit nicht, jedoch das Ergebnis der Auswertung wesentlich. Hierbei werden drei Unterparameter betrachtet. Ein Parameter repräsentiert die Kosten für die zeitliche Differenz zweier Zustände, ein weiterer Parameter definiert die Kosten für Einfügen, Löschen und Ersetzen zweier Zustände und ein dritter Parameter beinhaltet die zusätzlichen Kosten bei der Verwendung von seltenen oder unbekannten Zustandsfolgen. Diese Parameter sollten die Kosten für die einzelnen Operationen in einer logischen Weise repräsentieren, da ansonsten die Berechnung zu unerwünschten bzw. unlogischen Ergebnissen führen kann. Beispielsweise sollte das zeitliche Verschieben von Zuständen mit geringeren Kosten versehen werden, als das Löschen und Einfügen anderer Zustände, da eine zeitliche Varianz in der Fahrmanöverausführung nahezu jedes Mal vorhanden ist. Das Löschen eines Zustandes jedoch verändert die Sequenz wesentlicher.



---

Eine Gewichtung der Operationen von 1:3:2 (Zeitdifferenz : Einfügen/Löschen : Reihenfolge) hat dabei die beste Erkennungsleistung erzielt (vgl. auch Sylla 2015).

### **Gewichtung der Einzelabstände**

Der Parameter  $q$  steuert die Gewichtung der Einzelabstände. Bei einem zu geringen Wert wird der Fokus auf unähnlichere Sequenzen verschoben und eine Erkennung des Fahrmanövers kann nicht mehr trennscharf im Unterschied zu anderen Fahrmanövern durchgeführt werden. Wird der Wert zu hoch gewählt, werden nur die ähnlichsten Sequenzen berücksichtigt, was eine geringere Möglichkeit zur Detektion von Fahrmanövern mit höheren individuellen Schwankungen zulässt.

Es wird ein Gewicht von  $q = 0,9$  gewählt, welches den Beitrag des größten Wertes, in dieser Anwendung der Abstandswert der unähnlichsten Sequenz, von 10% wählt, sowie in geometrischer Reihenfolge die Gewichte bis zum geringsten Wert anpasst (vgl. auch Sylla 2015).

### **Ordnung des Algorithmus**

Die Ordnung beschreibt, wie viele Sequenzen aus dem aktuellen Fahrerverhalten erzeugt werden. Durch die Eigenschaften der Fuzzy Logik besteht immer die Möglichkeit, neben einer Sequenz mit den höchsten Aggregationswerten, weitere Sequenzen erzeugen zu können, welche jeweils niedrigere Aggregationswerte enthalten. Dadurch ist eine Beschreibung des Fahrerverhaltens entsprechend der individuellen Verhaltensdifferenzen noch genauer möglich. Da dieses Feature die Berechnungszeit stark beeinflusst, denn das Berücksichtigen einer Sekundärsequenz verdoppelt die Rechenzeit, wurde nur der Fall der Betrachtung einer Sekundärsequenz durchgeführt.

Eine Ordnung des Algorithmus von 2 hat die beste Erkennungsleistung erzielt (vgl. auch Sylla 2015).

### **Maximaler Zeithorizont**

Mit Hilfe dieses Parameters wird die analysierte Sequenzlänge definiert. Dieser Parameter gibt an, welcher Zeitraum vor einem Manöverflag zur Erzeugung der Sequenzen in der Datenbank benutzt wird. Wird dieser Parameter zu gering gewählt kann es passieren, dass einige frühe Merkmale des Fahrmanövers nicht erkannt werden können und somit der Zeithorizont der Prädiktion unnötig verkleinert wird. Wird der Parameter zu groß gewählt, steigt der Rechenaufwand an und es werden möglicherweise Merkmale gelernt, welche nicht zum eigentlichen Fahrmanöver gehören und somit die Übertragbarkeit auf dasselbe Fahrmanöver in anderem Kontext reduzieren.

Die Optimierung des Zeithorizontes führte zu einem Wert von 4,5s für den Fahrstreifenwechsel nach links und 3,0s für den Fahrstreifenwechsel nach rechts (vgl. auch Dosi 2016).

Eine detaillierte Darstellung der Parameteroptimierung und der Ergebnisse sind in den Arbeiten von Sylla (2015) und Dosi (2016) zu finden.

Da eine Optimierung aller Parameter mit einem heuristischen Verfahren sehr zeitaufwändig ist, wurde dieses anhand von einem begrenzten Trainingsdatensatz von 7 Probanden durchgeführt und mit Hilfe von Daten von 3 Probanden validiert. Im darauffolgenden Schritt (Kapitel 5.1.9) wird dann der vollständige Trainingsdatensatz verwendet, um die Performance des Algorithmus zu berechnen und zu validieren.

Die detaillierten Ergebnisse der Parameteroptimierung sind Sylla (2015) zu entnehmen. Es hat sich herausgestellt, dass die Beispielkonfiguration die besten Werte in Bezug auf die Performance zeigte. Die optimale Entscheidungsschwelle beträgt  $p^* = 65,3\%$  für den Fahrstreifenwechsel nach links. Dadurch werden eine  $TPR = 92,9\%$ , eine  $FPR = 18,0\%$  und eine  $AUC = 0,895$  bei einem mittleren Prädiktionshorizont von  $t_h = 0,90s$  erreicht.

Das jeweilige Hinzufügen des kumulierten Blinksignals erhöht den jeweiligen mittleren Prädiktionshorizont für den Fahrstreifenwechsel nach links auf  $t_h = 1,56s$  und nach rechts auf  $t_h = 2,66s$  bei jedoch gleichzeitiger starker Reduktion der Richtigerkennungsrate auf  $TPR = 50,0\%$  nach links und  $TPR = 89,1\%$  nach rechts.

#### 5.1.8. Bewertung und Validierung des Algorithmus

Zur Bewertung der Klassifizierungsleistung mit Hilfe der Wahrheitsmatrix wird die kontinuierliche Manöverwahrscheinlichkeit auf eine binäre Klassifizierung mit Hilfe einer Entscheidungsschwelle abgebildet und gemäß einer ROC-Analyse optimiert (vgl. auch Kapitel 3). Darüber hinaus ist die Bewertung der Prädiktion im Zeitbereich wesentlich, da ein warnendes FAS dem Fahrer rechtzeitig die notwendige Information bereitstellen muss und deshalb eine Fahrmanöverprädiktion als Qualitätsmaßstab die Bewertung des Zeithorizontes nutzen sollte. Auch dieses Kriterium wird berücksichtigt und in einer weiteren Stufe zu einer Bewertung eines binären Klassifikators mit Hilfe einer ROC-Kurve hinzugefügt.




Abbildung 52: ROC-Kurve

Würde nur das Kriterium einer ROC-Kurve berücksichtigt werden, also ausschließlich Sensitivität und Spezifität mit gleichem Gewicht verwendet, würde sich als Entscheidungsschwelle  $p^* = 87,7\%$  im dargestellten Beispiel ergeben. Daraus berechnet sich eine  $TPR = 85,7\%$  und eine  $FPR = 2,1\%$  bei einem Prädiktionshorizont von  $t_h = 0,77s$ . Berücksichtigt man jedoch auch den mittleren Prädiktionshorizont als Entscheidungskriterium und fügt die Werte zu einem Bewertungsmaßstab mit verschiedenen Gewichten in folgender Weise zusammen:

$$mix_{opt} = \frac{c_{TPR} \cdot TPR + c_{FPR} \cdot (1 - FPR) + c_{th} \cdot \frac{t_{h,mean}}{t_{h,max}}}{c_{TPR} + c_{FPR} + c_{th}},$$

so erhält man eine Formel mit der ein anderes Ergebnis für eine optimale Entscheidungsschwelle zur binären Klassifikation, entsprechend der gewünschten Bewertung der einzelnen Elemente, berechnet werden kann. Wählt man den Gewichtungsfaktor der Richtigerkennungsrate zu  $c_{TPR} = 2$ , der Falscherkennungsrate zu  $c_{FPR} = 3$  und des Zeithorizontes  $c_{th} = 1$ , wäre die optimale Entscheidungsschwelle nicht bei  $p^* = 87,7\%$  sondern bei  $p^* = 25,6\%$ . Dadurch wäre die Performance des Algorithmus bei  $TPR = 100\%$ ,  $FPR = 20,5\%$  und  $t_h = 1,35s$ .




Abbildung 53: Bewertung von TPR, FPR und  $t_h$

In Abbildung 53 ist der Verlauf der TPR (grün), FPR (rot), des Zeithorizontes  $t_h$  (blau) und der kombinierten Entscheidungsschwelle (schwarz) dargestellt. Eine normale ROC-Analyse führt zu einer Entscheidungsschwelle von  $p^* = 87,7\%$  (rot gepunktet), die kombinierte Entscheidungsschwelle führt zu dem Wert  $p^* = 25,6\%$  (grün gepunktet). Die Auswahl einer anderen Entscheidungsschwelle kann notwendig sein, wenn verschiedene FAS Informationen der Fahrmanöverprädiktion erhalten sollen.

Für sicherheitskritische Systeme, wie zum Beispiel einen automatischen Eingriff in die Fahrzeugführung, kann mit einer hohen Bewertung für die Fehlerkennungsrate, diesem Wert mehr Gewicht zugeordnet werden und eine in diesem Fall hohe Entscheidungsschwelle präferieren. Sollte ein FAS jedoch einen großen Prädiktionshorizont benötigen um eine Fahrerinformation möglichst früh dem Fahrer darbieten zu können und um diesem ausreichend Reaktionszeit zu verschaffen, unter Inkaufnahme einer höheren Fehlerkennungsrate, so ist das auch möglich. In Abbildung 54 ist der Einfluss auf die Entscheidungsschwelle in Bezug auf die Wahrscheinlichkeit und den Zeithorizont dargestellt.




Abbildung 54: Entscheidungsschwelle in Bezug zu Wahrscheinlichkeits- und Zeithorizontverlauf der Prädiktion

Während die hohe Schwelle von  $p^* = 87,7\%$  (rot) aus der ROC-Analyse erst spät eine Klassifizierung des Manövers zulässt, präferiert die zweite Variante eine niedrige Entscheidungsschwelle mit  $p^* = 25,6\%$  (grün). Dieses Beispiel verdeutlicht die Möglichkeit, zusätzlich zu den Werten der Spezifität und Sensitivität auch den Zeithorizont in einer Entscheidungsschwelle zur binären Klassifizierung zu berücksichtigen.

### Kreuzvalidierung

Bezüglich der aufgezeigten Möglichkeiten der Kreuzvalidierung (vgl. Kapitel 3) wird dieses Verfahren zur Bewertung der Prädiktionsleistung eingesetzt. Aufgrund der realistischen Performanceabschätzung wird das Verfahren der leave-one-out Kreuzvalidierung (LOOCV) eingesetzt. Das Verfahren entspricht einer Übertragung auf eine reale Anwendung, da hierfür viele Trainingsdaten verwendet werden um dann auf den Einzelfall (den aktuellen Fahrer) angewendet zu werden.

Da dieses Verfahren aufgrund der mehrfach wiederholten Trainingsschritte des Algorithmus auf die gesamten Daten eine hohe Trainingszeit beansprucht, wurde im ersten Schritt, zur Identifikation der optimalen Eingangsgrößen, auf eine reduzierte Anzahl von Trainingsdaten zurückgegriffen. Dabei hat sich ein  $n=9$  als guter Kompromiss zwischen realistischer Abschätzung der Erkennungsleistung und Trainingsaufwand herausgestellt. Die Ergebnisse sind in Tabelle 13 dargestellt.

Tabelle 13: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach links für  $n=9$  Probandendatensätze mit Variation der Eingangssignale

Konfiguration	n	TPR	FPR	AUC	$t_h$	$t_{h,err}$
1) $\delta; d_{lat}; TLC$	9	92,48%	6,22%	0,947	0,786s	0,74s
2) $\delta; d_{lat}; TLC; bl_{\Sigma}$	9	69,99%	15,54%	0,800	2,301s	3,36s
3) $TLC; \alpha_{head}; bl_{\Sigma}$	9	96,23%	10,72%	0,950	1,347s	1,48s
4) $d_{lat}; TLC; \alpha_{head}; bl_{\Sigma}$	9	71,33%	12,62%	0,828	2,108s	3,18s
5) $d_{lat}; TLC; \alpha_{head}$	9	93,69%	3,53%	0,969	0,740s	0,80s
6) $\Psi; TLC; bl_{\Sigma}$	9	89,00%	8,67%	0,916	1,002s	1,97s

In Tabelle 13 sind die Ergebnisse der Performance verschiedener Algorithmuskonfigurationen mit unterschiedlichen Eingangssignalen aufgeführt. Erwartungsgemäß zeigen die Konfigurationen mit Nutzung der Signale, welche auch bei der Bewertung mit dem Bewertungsmaßstab gut abgeschnitten haben, eine gute Leistungsfähigkeit. Die area-under-curve (AUC) bewertet dabei nicht nur den idealen Punkt aus der Kombination von Sensitivität und Spezifität, sondern den gesamten Verlauf der Kurve und lässt so einen Vergleich verschiedener Konfigurationen zu.

Die Konfiguration mit time-to-linecrossing, Winkel des Fahrzeuges zur Fahrstreifenmarkierung und kumulierte Blinkdauer ( $TLC; \alpha_{head}; bl_{\Sigma}$ ), erreicht die höchste Richtigerkennungsrate (TPR) bei einer mittleren Fehlerkennungsrate (FPR) und der zweithöchsten AUC. Der mittlere prädizierte Zeithorizont ( $t_h$ ) liegt im mittleren Bereich der Konfigurationen, bei einem zeitlichen Fehler ( $t_{h,err}$ ) auf demselben Niveau. Die Konfiguration mit dem Abstand zur Fahrstreifenmarkierung, TLC und Winkel ( $d_{lat}; TLC; \alpha_{head}$ ), erreicht die niedrigste FPR bei der zweithöchsten TPR. Die AUC ist am höchsten bei geringstem  $t_h$  und  $t_{h,err}$  auf ähnlichem Niveau, wie die  $t_h$ . Die Konfiguration mit Lenkwinkel, Abstand und TLC ( $\delta; d_{lat}; TLC$ ) liegt knapp hinter den beiden besten Konfigurationen, ohne in einer der Einzelwertungen zu überzeugen.

Die weiteren Konfigurationen besitzen deutlich geringere TPR bei z.T. höheren FPR und erreichen somit geringere AUC. Einzig im Bereich des mittleren Prädiktionshorizontes können die Konfigurationen überzeugen. Der durchschnittlich höhere Wert von  $t_h$  bei der Nutzung des kumulierten Blinksignals folgt daraus, dass der Blinker früher gesetzt wird, als weitere Signale, welche vor einem Fahrstreifenwechsel zu einer Prädiktion beitragen. Allerdings wird nicht bei jedem Fahrstreifenwechsel der Blinker durch die Probanden benutzt, wodurch hier die TPR sinkt bzw. die FPR steigt.

Zusammenfassend schneiden die Konfigurationen mit Informationen zur Fahrzeugposition relativ zur Fahrstreifenmarkierung am besten ab. Das war bereits nach der Auswertung des Bewertungsfaktors dieser Signale zu erwarten. Es haben sich zwei Konfigurationen als am besten herausgestellt (Zeile 3 und 5 in Tabelle 13). Diese werden weiter verfolgt.

Die beiden besten Konfigurationen (3 und 5 in Tabelle 13) wurden daher für den Fahrstreifenwechsel nach rechts validiert:

Tabelle 14: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach rechts für  $n=9$  Probandendatensätze der beiden besten Kombinationen von Eingangssignalen

Konfiguration	n	TPR	FPR	AUC	$t_h$	$t_{h,err}$
7) $TLC; \alpha_{head}; bl_{\Sigma}$	9	94,40%	9,40%	0,951	1,015s	0,27s
8) $d_{lat}; TLC; \alpha_{head}$	9	100%	5,84%	0,988	0,582	0,19s

Die beiden Konfigurationen liefern auch für die Prädiktion des Fahrstreifenwechsels (FSW) nach rechts annehmbare Ergebnisse. Die Werte für TPR steigen bei ähnlicher, bzw. leicht sinkender FPR. Die gestiegene AUC weist darauf hin, dass die Konfigurationen für die Erkennung des FSW nach rechts nochmals besser geeignet sind, als für den FSW nach links. Vor allem der zeitliche Prädiktionsfehler nimmt bei beiden Konfigurationen stark ab. Die erste Konfiguration weist einen geringeren Prädiktionshorizont für den FSW nach links auf, die zweite Konfiguration besitzt für den FSW nach rechts einen höheren mittleren Prädiktionshorizont. Das deutet darauf hin, dass die Nutzung des Blinkers zeitlich erst später, als beim Fahrstreifenwechsel nach links, erfolgt ist und somit eine zutreffende Erkennung im Vergleich erst zeitlich später möglich ist. Die Merkmale zur Fahrzeugposition zur

Fahrstreifenmarkierung sind davon nicht betroffen und erreichen eine weiterhin sehr gute Erkennungsleistung.

Hieran lässt sich erkennen, dass der verwendete Algorithmus und das verwendete Abstandsmaß auf valide Prädiktoren angewiesen sind. Dieses bedeutet, dass Prädiktoren, welche regelmäßig vor einem Fahrstreifenwechsel auftreten, die Erkennungsleistung steigern, während Signale, welche frühzeitig vor einem Fahrstreifenwechsel auftreten, zwar den Prädiktionshorizont vergrößern können, jedoch zu Lasten der Erkennungsraten. Dies bestätigt die Annahme, dass der Algorithmus aufgrund des verwendeten Abstandsmaßes sensibel auf nicht valide Prädiktoren reagiert und auf eine geeignete Vorauswahl der Eingangsgrößen angewiesen ist. Dieser Umstand ist vor allem bei der Integration von Fahrerbeobachtungsdaten relevant, da diese zwar einen großen Zeithorizont besitzen bei einer jedoch reduzierten Validität.

#### 5.1.9. Erweiterung der Trainingsdaten

Nachdem an der reduzierten Menge an Datensätzen die optimale Kombination an Eingangsgrößen ermittelt wurde, wird für eine vollständige Validierung die Menge der Trainingsdaten auf alle vorhandene Probandendatensätze (n=32) erweitert.

Tabelle 15: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach links für n=32 Probandendatensätze der beiden besten Kombinationen von Eingangssignalen

Konfiguration	n	TPR	FPR	AUC	$t_h$	$t_{h,err}$
9) $TLC; \alpha_{head}; bl_{\Sigma}$	32	98,79%	7,34%	0,978	0,906s	0,93s
10) $d_{lat}; TLC; \alpha_{head}$	32	98,45%	4,05%	0,987	0,659s	0,86s

Durch die Verwendung von mehr Datensätzen steigt bei beiden Konfigurationen die Richtigerkennungsrate (TP) um 2,56% bzw. 4,76%. Bei der ersten Konfiguration sinkt zusätzlich die Fehlerkennungsrate (FPR) um 3,38%, bei der zweiten Konfiguration steigt die FPR von einem bereits vorher sehr guten Wert leicht um 0,52% an. Der Zeithorizont verringert sich bei beiden Konfigurationen um 0,44s bzw. 0,08s. Der zeitliche Fehler der Prädiktion sinkt bei der ersten Konfiguration deutlich um 0,55s, wobei er bei der zweiten Konfiguration um 0,06s ansteigt.

Tabelle 16: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach rechts für n=32 Probandendatensätze der beiden besten Kombinationen von Eingangssignalen

Konfiguration	n	TPR	FPR	AUC	$t_h$	$t_{h,err}$
11) $TLC; \alpha_{head}; bl_{\Sigma}$	32	99,20%	5,48%	0,978	0,662s	0,27s
12) $d_{lat}; TLC; \alpha_{head}$	32	98,54%	3,94%	0,984	0,451s	0,24s

Bei der Erkennung des Fahrstreifenwechsels nach rechts verbessert sich bei der ersten Konfiguration die TPR um 4,8% bei einer reduzierten FPR von 3,92%. Bei der zweiten Konfiguration sinken TPR um 1,46% und FPR um 1,9%. Die AUC liegt bei beiden Konfigurationen auf nahezu ähnlichem Niveau mit einem Unterschied von 0,03. Der zeitliche Prädiktionshorizont nimmt bei beiden Konfigurationen um 0,35s bzw. 0,13s ab bei einem zeitlichen Prädiktionsfehler auf vergleichbarem Niveau.

Durch die Verwendung einer größeren Anzahl an Trainingsdaten ist die Variation der Fahrmanöver nochmals größer. Dadurch steigt in den meisten Fällen die Richtigerkennungsrate bei reduzierter

---

Falscherkennungsrate. Das beeinflusst ebenso die AUC, die sich überwiegend leicht verbessert. Der mittlere Prädiktionshorizont sinkt durch die Nutzung einer größeren Menge an Trainingsdaten. Dieses resultiert aus der höheren Varianz der vorliegenden Manöver und eine sichere Erkennung ist dadurch erst zu einem späteren Zeitpunkt möglich. Es ist hier jedoch schon eine Sättigung erkennbar. Mit den gezeigten Konfigurationen ist eine weitere Steigerung der Leistungsfähigkeit durch die Nutzung weiterer Trainingsdaten nicht zu erwarten.

Das bedeutet entweder, dass der verwendete Algorithmus an der Grenze seiner Leistungsfähigkeit durch die verwendeten Trainingsdaten angekommen ist, oder die verwendeten Probanden eine so große Variation im Fahrerverhalten abbilden, dass dieses repräsentativ für eine sehr große Menge an Fahrern im kontrollierten Feld ist. Ein Hinzufügen weiterer Signale zu einer funktionierenden Konfiguration führte dabei nicht zu einem Anstieg der Leistungsfähigkeit. Durch das Hinzufügen steigen die Komplexität der Manöversequenzen und die inkorporierte Unsicherheit an. Daher resultiert nur ein Hinzufügen valider Prädiktoren zu einer Verbesserung der Leistungsfähigkeit.

Zusammenfassend lässt sich aus der Kreuzvalidierung ableiten, dass der entwickelte Algorithmus in der Lage ist, Fahrstreifenwechsel auf der Basis der Versuchsdaten zu erkennen und zu prädictieren. Dabei existieren ein hoher Einfluss der Eingangssignale auf die Erkennungsleistung sowie ein Einfluss der Algorithmusparameter auf das Ergebnis. Es werden in den beiden hauptsächlich betrachteten Algorithmuskonfigurationen hohe Richtigerkennungsraten bei geringen Falscherkennungsraten erreicht. Die prädictierten Zeithorizonte sind gering gegenüber den Anforderungen der Entwicklung. Eine Integration zeitlich früherer Merkmale valider Prädiktoren ist notwendig, um die Leistungsfähigkeit dem Bedarf weiter anzunähern.

## 5.2. Integration von Fahrerbeobachtung

Die Integration von Merkmalen zur Fahrerbeobachtung ermöglicht die Chance einer früheren Fahrmanöverprädiktion (vgl. Kapitel 2.3). In diesem Abschnitt wird die Integration von Daten zur Fahrerbeobachtung in den Algorithmus zur Fahrmanöverprädiktion beschrieben, um die Leistungsfähigkeit auf das angestrebte Niveau zu steigern.

Im ersten Schritt wurden dazu die geeignetsten Merkmale zur Fahrmanöverprädiktion ausgewählt (vgl. Kapitel 4.3). Es wurden dabei nicht nur direkte Signale, sondern auch davon abgeleitete Größen berücksichtigt und analysiert. Es hat sich herausgestellt, dass sich der horizontale Kopfwinkel (Headheading,  $\beta_{Kopf}$ ) als bester Prädiktor in diesem Kontext eignet. Daher wird dieser als weitere Eingangsgröße in den bestehenden Algorithmus integriert. Dazu werden die besten Kombinationen des Algorithmus mit Fahrzeugdaten um das Headheading ergänzt. Es ergeben sich folgende Performance Zahlen:

Tabelle 17: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach links für  $n=9$  Probandendatensätze mit Daten der horizontalen Kopffrotation

Konfiguration	n	TPR	FPR	AUC	$t_h$	$t_{h,err}$
3) $TLC; \alpha_{head}; bl_{\Sigma}$	9	96,23%	10,72%	0,950	1,347s	1,48s
13) $TLC; \alpha_{head}; bl_{\Sigma}; \beta_{Kopf}$	9	75,85%	21,51%	0,799	2,414s	2,75s
14) $TLC; \alpha_{head}; \beta_{Kopf}$	9	89,54%	4,51%	0,951	0,821s	0,76s
5) $d_{lat}; TLC; \alpha_{head}$	9	93,69%	3,53%	0,969	0,740s	0,79s
15) $d_{lat}; TLC; \alpha_{head}; \beta_{Kopf}$	9	68,76%	11,70%	0,816	1,319s	1,79s
16) $\delta; d_{lat}; TLC; \beta_{Kopf}$	9	74,38%	24,67%	0,779	2,487s	3,30s
17) $\delta; d_{lat}; TLC; bl_{\Sigma}; \beta_{Kopf}$	9	72,84%	32,94%	0,703	3,469s	5,14s
18) $TLC; bl_{\Sigma}; \beta_{Kopf}$	9	80,92%	9,41%	0,859	1,334s	1,02s
19) $\alpha_{head}; bl_{\Sigma}; \beta_{Kopf}$	9	79,41%	12,83%	0,846	1,385s	1,28s

Beim Hinzufügen vom horizontalen Winkel des Fahrerkopfes ( $\beta_{Kopf}$ ) erhöht sich erwartungsgemäß der Zeithorizont  $t_h$  der Prädiktion, da die Kopffrotation ein frühes Merkmal zur Fahrmanöverprädiktion darstellt. Allerdings sinkt durch das Hinzufügen die TPR und die FPR steigt. In der ROC Auswertung der AUC sind die Konfigurationen insgesamt schlechter, auch wenn sie einen vergrößerten Zeithorizont der Prädiktion ermöglichen. Das hängt hauptsächlich am verwendeten Abstandsmaß. Dieses ist auf eine hohe Validität der Merkmale angewiesen. Merkmale, welche zwar eine sehr frühe Prädiktion ermöglichen, allerdings nicht konsistent häufig bei einer Manöverausführung auftreten, erhöhen den mittleren Prädiktionshorizont bei gleichzeitiger Verschlechterung der Erkennungsraten (vgl. Kopffrotation im Kapitel 3.5). Der Algorithmus generiert Verhaltensketten aus den gewählten Eingangsgrößen und ist dabei abhängig vom gezeigten Verhalten der Fahrer.

### 5.2.1. Stacking von Algorithmen

Das unabhängige Verwenden von Merkmalen ist mit Hilfe von Stacking mehrerer Algorithmen möglich. In diesem Fall wurde ein einfacher, gut erforschter Algorithmus (Entscheidungsbäume vgl. Kapitel 2.4) für das Stacking eingesetzt, um das Potential dieser Methodik aufzuzeigen und die Prädiktionsleistung zu verbessern.

Die Integration der Fahrerbeobachtung in einen Algorithmus zur Fahrmanöverprädiktion wurde durch die studentische Arbeit von Achieser (2016) unterstützt.

Zur Aufstellung eines Entscheidungsbaumes muss ein Entscheidungskriterium für das Training ausgewählt werden. In diesem Fall wurde der Gini Index ausgewählt, da dieser ein häufig verwendetes und geeignetes Entscheidungskriterium beim Training von Entscheidungsbäumen ist und eine gute Performance erlaubt. Der Gini Index (Gini diversity index, GDI) berechnet sich zu  $GDI = 1 - \sum_i p^2(Class\ i)$ , wobei  $p(Class\ i)$  dem beobachteten Anteil der Klasse  $i$  in einem betrachteten Knoten entspricht. Dieser Index hat einen Wertebereich von  $[0,1]$ , wobei  $GDI = 0$  den Fall eines reinen Knotens aufweist, was bedeutet, dass in allen Fällen unterhalb dieses Knotens ausschließlich Elemente einer Klasse auftreten.



---

Im ersten Schritt wurde ein Entscheidungsbaum trainiert, ohne die Informationen des entwickelten Algorithmus aus Kapitel 5.1 zu verwenden, um die Eignung und Fähigkeit des Entscheidungsbaumes für diesen Anwendungsfall zu erkennen. Dazu wurde jeweils ein Entscheidungsbaum für die Erkennung von Fahrstreifenwechsel nach links mit Fahrzeugdaten, Umfelddaten und Daten zur Kopfdrotation bzw. Daten zum Blickverhalten trainiert. Folgende Signale wurden verwendet:

- Fahrerbeobachtungssignale:
  - o Kopfwinkel
  - o Kopfwinkelgeschwindigkeit
  - o Relative Häufigkeit von Kopfdrehungen nach links ( $>0,5\text{rad}$ ) der letzten 5s
  - o Relative Häufigkeit von Kopfdrehungen nach rechts ( $<-0,5\text{rad}$ ) der letzten 5s
  - o Maximaler Kopfwinkel der letzten 3s
  - o Minimaler Kopfwinkel der letzten 3s
  - o Standardabweichung des Kopfwinkels über 3s
  - o Maximale Kopfwinkelgeschwindigkeit der letzten 3s
  - o Minimale Kopfwinkelgeschwindigkeit der letzten 3s
- Fahrzeugsignale:
  - o Fahrzustand (Fahrzeuggeschwindigkeit  $>10\text{km/h}$ )
  - o Gierrate
- Umfeldsignale:
  - o TLC
  - o Straßenkrümmung
- Algorithmus Fuzzy Logik und Edit Distance
  - o Wahrscheinlichkeit für FSW links
  - o Wahrscheinlichkeit für FSW rechts
  - o Zeithorizont bis FSW links
  - o Zeithorizont bis FSW rechts

Durch die Variation der Baumgröße, Anpassung der Sampling-Gewichte und nachträgliches Beschneiden der Bäume (post-pruning), hat sich folgende Leistungsfähigkeit des Entscheidungsbaumes zur Klassifikation des Fahrstreifenwechsels nach links ergeben:




Abbildung 55: Leistungsfähigkeit des Entscheidungsbaumes ohne Kombination mit dem im Kapitel 5.1 gezeigten Algorithmus als Vergleichsmaßstab mit Kopfbewegungsdaten (links) und Kopf- und Blickbewegungsdaten (rechts)

In der Grafik kann man erkennen, dass mit steigender Baumgröße die TPR und auch die FPR ansteigen. Eine sehr hohe Baumgröße bringt dabei das Problem des overfittings mit sich, wodurch die Auswahl eines kleineren Baumes die größtmögliche Performance ohne overfitting verspricht. Die Nutzung der Gierrate und Straßenkrümmung durch ein Spurerkennungssystem oder digitale Karten in Verbindung mit GPS kann die Fehlerkennungsrate von Fahrstreifenwechsel in Kurven positiv beeinflussen (vgl. auch Achieser 2016).

Die grüne Kurve repräsentiert in der Abbildung die Erkennungsrate des Systems zum Zeitpunkt  $t = -2s$  vor dem Berühren der Fahrstreifenmarkierung durch das Vorderrad ( $TLC = 0s$ ). Dieses stellt die Abschätzung des Potentials des Systems für eine frühzeitige Erkennung eines Fahrstreifenwechsels dar. Die blaue Kurve repräsentiert hierbei alle Fahrmanöver, die bis zum Berühren der Fahrstreifenmarkierung erkannt worden sind. Die Entscheidungsbäume, welche Kopfbewegungsdaten verwenden, erreichen dabei eine Performance mit einer TPR von nahezu 90% bei einer FPR von unter 5%. Das Hinzufügen von Daten zur Blickbewegung verschlechtert die TPR auf ca. 60% bei vergleichbarer FPR. Dieses deckt sich mit den Erkenntnissen aus Kapitel 4.3.

Die Performance eines Entscheidungsbaumes ohne Kombination mit dem Algorithmus aus Kapitel 5.1 zeigt das Potential des entwickelten Algorithmus aus dem vorigen Abschnitt auf. Die Leistungsfähigkeit liegt höher als die eines Entscheidungsbaumes. Im Weiteren wird der Algorithmus mit Fuzzy Logik und Edit Distance mit dem Entscheidungsbaum kombiniert.

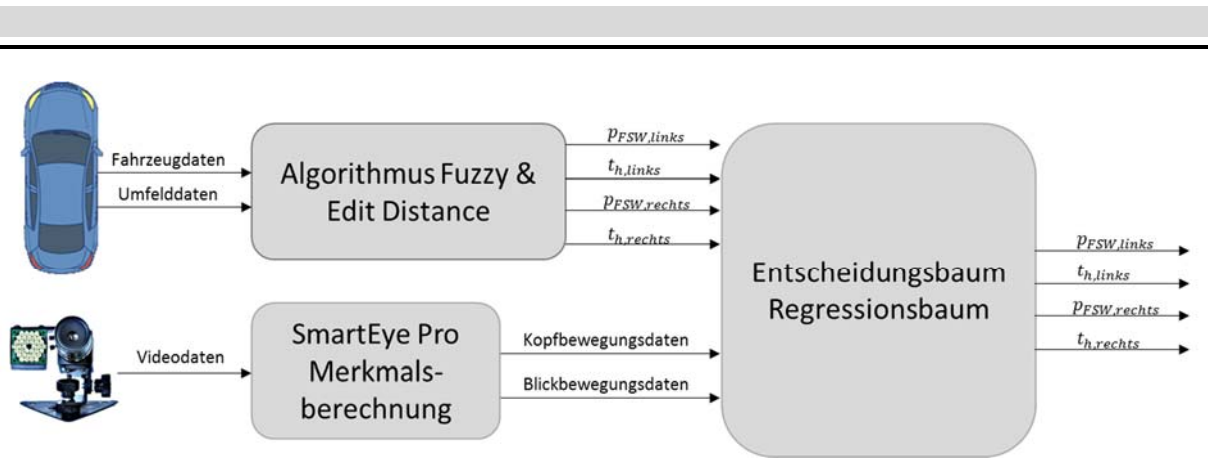


Abbildung 56: Schematische Darstellung des Algorithmen Stacking (Foto SmartEye Kamera von Smart Eye AB (2015))

Die vier Ausgaben zur Wahrscheinlichkeit des Fahrstreifenwechsels nach links  $p_{FSW,links}$  und nach rechts  $p_{FSW,rechts}$  sowie die zugehörigen prädizierten Zeithorizonte  $t_{h,links}$  und  $t_{h,rechts}$  des Algorithmus mit Fuzzy Logik und Edit Distance, werden zusätzlich zu den Daten und berechneten Merkmalen des SmartEye Fahrerbeobachtungssystems als Eingangsgrößen für den Entscheidungsbaum genutzt. Daraus werden mit Hilfe des Entscheidungsbaumes neue Wahrscheinlichkeiten für die beiden Fahrstreifenwechsel und neue Zeithorizonte prädiziert.

Die Verbesserung der Performance ist in Abbildung 57 zu erkennen.




Abbildung 57: Leistungsfähigkeit des Entscheidungsbaumes mit Kopfbewegungsdaten ohne (links) und mit Stacking (rechts)

Die rechte ROC-Kurve stellt die Performance des gestackten Algorithmus dar. Die TPR steigt auf über 90% an bei gleichbleibender FPR. Auch die Varianz der TPR sinkt erkennbar. Bei einer Baumgröße von 80 Knoten, dieses ist der Punkt, an dem durch weiteres Vergrößern des Entscheidungsbaumes kein signifikanter Performancegewinn mehr zu erzielen ist, beträgt die  $TPR = 97,31\% \pm 3,88\%$  bei einer  $FPR = 1,42\% \pm 0,44\%$ .

Im nächsten Schritt wurde noch der Einfluss der Eingangsgrößen auf die Prädiktion betrachtet. Dieses ist mit Hilfe der sog. Feature Importance möglich. Die Feature Importance ist definiert als die Reduktion

des durchschnittlichen Risikos der Entscheidung an einem Knoten. Diese berechnet sich aus der Wahrscheinlichkeit zur Fehlklassifizierung, gewichtet mit dem Verhältnis der Beobachtungen, die die Bedingungen des Knotens erfüllen.




Abbildung 58: Darstellung der relevantesten Eingangssignale des Entscheidungsbaumes anhand der Feature Importance

Es ist zu erkennen, dass für die Prädiktion des FSW nach links, die Ausgabe des Algorithmus mit Fuzzy Logik und Edit Distance die höchste Feature Importance erreicht, was bedeutet, dass diese die Prädiktion am stärksten positiv beeinflusst. Weitere wichtige Merkmale sind die Werte zur Prädiktion des Zeithorizontes und das Maximum des Kopfwinkels über ein Zeitfenster von 3 Sekunden sowie die Werte Gierrate, Fahrzustand (is driving) und Straßenkrümmung. Die letzten beiden Werte dienen zur Reduktion von Fehlerkennungen eines FSW vor und in Kurven, im Stillstand und bei sehr niedriger Geschwindigkeit. Weitere Merkmale mit Einfluss auf das Ergebnis sind die Wahrscheinlichkeit für den Fahrstreifenwechsel nach rechts und weitere Kopfbewegungsmerkmale, wie der gefilterte Kopfwinkel und die relative Häufigkeit der Kopfdrehung über ein Zeitfenster von 5 Sekunden. Die weiteren Faktoren besitzen nur sehr geringen oder keinen Einfluss auf die Erkennungsleistung und sollten gem. der Theorie von Occam's Razor entfernt werden (vgl. Kapitel 2.5).

Im nächsten Schritt wird der Entscheidungsbaum auf eine Klassifizierung von Fahrstreifenwechsel nach links und rechts erweitert. Dazu werden die entsprechenden Merkmale mit den wesentlichen Werten der Feature Importance als Eingangsgrößen verwendet und die Entscheidungsbäume zur Detektion von drei Klassen trainiert: FSW nach links, FSW nach rechts und kein FSW.




Abbildung 59: Leistungsfähigkeit des 3-Klassen Entscheidungsbaumes mit reduzierten Eingangssignalen des Entscheidungsbaumes und Stacking für die Fahrstreifenwechsel nach links und rechts

Durch das Erweitern der Entscheidungsbäume auf drei Klassen steigt die TPR für den FSW nach links leicht an, bei gleichbleibender FPR. Die Erkennungsraten für den FSW nach rechts liegen in einem vergleichbaren Bereich. Eine Erklärung für die schlechtere frühzeitige Erkennung kann aus dem Verhalten der Fahrer begründet sein, da nur 30% bzw. 14% der FSW mit einer Kopfbewegung zum Schulterblick abgesichert werden (vgl. Kapitel 3.5). Weiterhin ist, durch die Eigenschaften des Versuchsaufbaus, das effektiv nutzbare Zeitfenster für eine Prädiktion bei einem FSW nach rechts kleiner (6,5s pro Runde im Unterschied zu 10s pro Runde), was zu einer leichten Disbalance der Klassen zum Nachteil der Erkennungsleistung des FSWs nach rechts führt.

## Regression Trees

Da die Prädiktionsleistung des Zeithorizontes weiterer Verbesserung bedarf (vgl. Kapitel 5.1.9) wird zusätzlich ein Regressionsbaum verwendet. Dafür sind die bereits verwendeten und aufgezeigten Signale der Fahrerkopfbewegung sowie der Fahrzeugdaten geeignet:

- Fahrerbeobachtungssignale:
  - Kopfwinkel
  - Kopfwinkelgeschwindigkeit
  - Zeit seit letzter Kopfdrehung
- Fahrzeugsignale:
  - Lenkwinkel
- Umgebungssignale:
  - TLC

Weiterhin wird auf den Lenkwinkel zurückgegriffen, da dieser einen charakteristischen Verlauf während eines Fahrstreifenwechsels aufweist und darüber hinaus auch über verschiedene Probanden relative Ähnlichkeit, bezogen auf die zeitliche Lokalisierung im Verhältnis zur Manövermarkierung, besitzt. Somit sollte die Genauigkeit der zeitlichen Prädiktion verbessert werden können. Es wurde jeweils für die FSW nach links und rechts ein Regressionsbaum trainiert.




Abbildung 60: Leistungsfähigkeit des Regressionsbaumes in Bezug auf den zeitlichen Fehler der Prädiktion für Fahrstreifenwechsel nach links und rechts

Anhand der Grafik ist ersichtlich, dass sich der zeitliche Fehler der Prädiktion des Zeithorizontes mit steigender Baumgröße im Mittel der 0s annähert. Ab einem gewissen Punkt, hier bei 32 Knoten, steigt die Performance nicht mehr mit der Steigerung der Baumkomplexität, weshalb diese Baumgröße das Optimum für die Zeitprädiktion darstellt. Der Prädiktionsfehler liegt bei  $t_{h,err} = -0,06s \pm 1,00s$ . Der Fahrstreifenwechsel nach rechts kann bei einer Baumgröße von ebenfalls 32 Knoten mit einer zeitlichen Genauigkeit von  $t_{h,err} = -0,23s \pm 1,45s$  präzisiert werden.

In beiden Fällen verschlechtert sich die Performance beim zusätzlichen Hinzufügen von Daten zur Blickbewegung im Bereich des mittleren Fehlers und der Standardabweichung. Details dazu sind Achieser (2016) zu entnehmen.

### 5.2.2. Bewertung und Validierung des Algorithmus

Abschließend wurden die gestackten Algorithmen bezüglich ihrer Performance zusammenfassend bewertet. Dabei wurden die Entscheidungsbäume mit 67% der Probandendaten trainiert und an 33% der Daten getestet. Der 2-Klassen-Entscheidungsbaum wurde auf 80 Knoten und der 3-Klassen-Entscheidungsbaum auf 90 Knoten beschnitten, die Regressionsbäume auf 32 Knoten für den FSW nach links und auf 12 Knoten für den FSW nach rechts.

Tabelle 18: Leistungsfähigkeit der gestackten Algorithmen des Fahrstreifenwechsels für n=32 Probandendatensätze im Vergleich zur Leistungsfähigkeit des Algorithmus ohne angeschlossenen Entscheidungs- und Regressionsbaum

Konfiguration	Manöver	TPR	FPR	$t_h$	$t_{h,err}$
10) Fuzzy Logik & Edit Distance	FSW links	98,45%	4,05%	0,66s	0,86s
14) Fuzzy Logik mit Kopfbewegung	FSW links	89,54%	4,51%	0,82s	0,76s
12) Fuzzy Logik & Edit Distance	FSW rechts	98,54%	3,94%	0,45s	0,24s
20) Fuzzy mit 2-Klassen-Entscheidungsbaum	FSW links	91,03%	3,11%	2,58s	0,55s
21) Fuzzy mit 3-Klassen-Entscheidungsbaum	FSW links	92,80%	4,01%	2,88s	0,56s
22) Fuzzy mit 3-Klassen-Entscheidungsbaum	FSW rechts	97,92%	3,76%	2,20s	0,76s

Die Leistungsfähigkeit der verbundenen Algorithmen ist dabei höher als die Performance der einzelnen Algorithmen. Der 3-Klassen-Entscheidungsbaum mit dem Algorithmus aus Fuzzy Logik und Edit Distance ist in der TPR etwas schlechter als der einzelne Algorithmus aus Fuzzy Logik und Edit Distance ohne Kopfbewegungsdaten. Er überzeugt jedoch durch seine sehr viel geringere FPR und durch den deutlich gesteigerten mittleren Zeithorizont der Prädiktion sowie des geringeren Fehlers der Zeitprädiktion. Der gestackte Algorithmus zeigt gegenüber dem einzelnen Algorithmus mit Fuzzy Logik und Edit Distance mit Kopfbewegungsdaten, neben deutlich besseren Richtig- und Falscherkennungsraten, eine höhere Zeitprädiktion sowie einen geringeren Zeitfehler auf.

Für die FSW nach rechts gelten ähnliche Erkenntnisse. Außer beim mittleren zeitlichen Fehler, hier liefert der einzelne Algorithmus einen geringeren Fehler, jedoch bei deutlich geringerem Zeithorizont. Bezogen auf den Zeithorizont ist der zeitliche Fehler der Prädiktion jedoch relativ betrachtet größer.

### 5.3. Implementierung in Demonstratorfahrzeug

Die bis hierhin entwickelten Algorithmen wurden in ein Demonstratorfahrzeug mit Hilfe prototypischer Hardware integriert.





Abbildung 61: Demonstratorfahrzeug Opel Insignia zur Integration des Algorithmus

Das Fahrzeug ist ein Opel Insignia Modelljahr 2014. Es besitzt eine leicht modifizierte Frontkamera, um die Informationen der Position des Fahrzeuges relativ zu den Fahrstreifenmarkierungen über CAN-Bus zu senden. Im Kofferraum ist die Hardware installiert, auf der der Algorithmus ausgeführt wird, sowie alle Komponenten, die den Algorithmus mit Daten versorgen und die vom Algorithmus berechneten Daten versenden. Die Hardwarearchitektur ist in Abbildung 62 dargestellt.



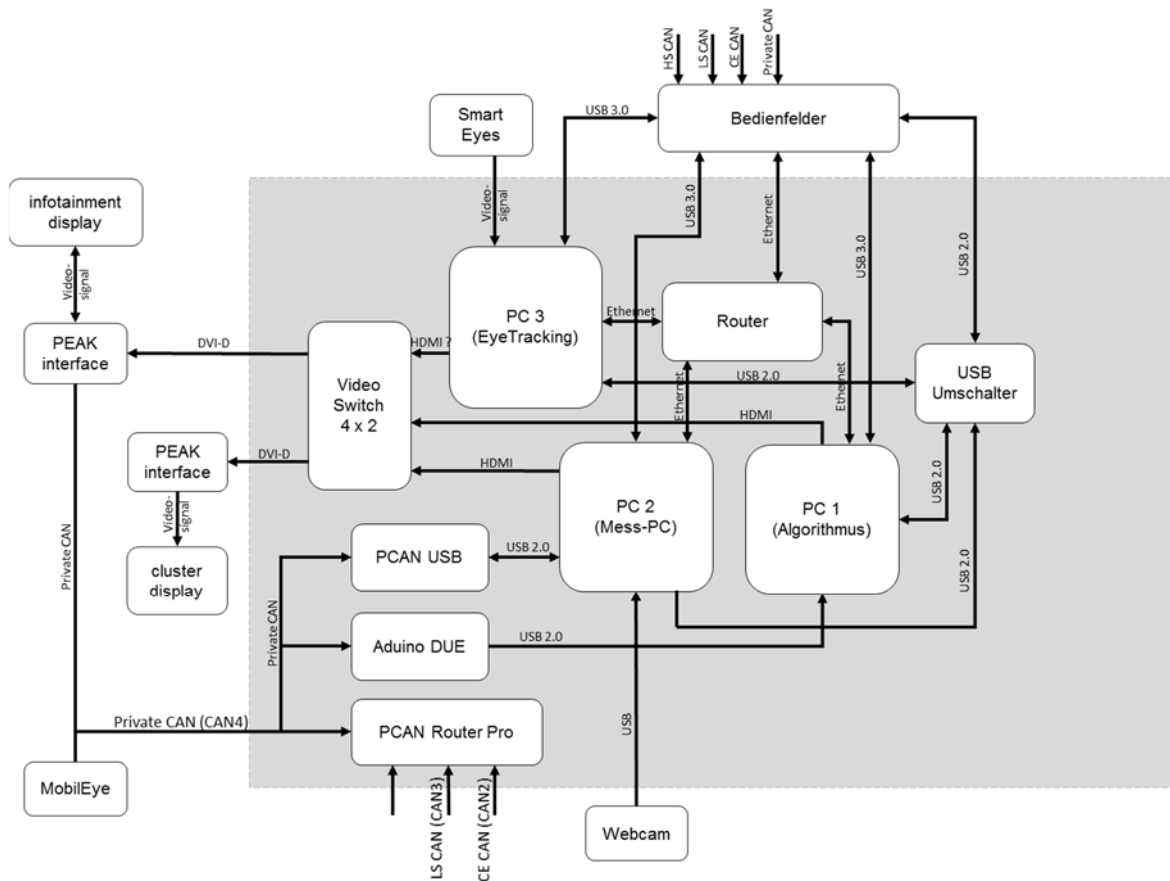


Abbildung 62: Hardwarearchitektur der Fahrmanöverprädiktion im Demonstratorfahrzeug

Kern der Architektur ist ein Car-PC handelsüblicher Bauweise mit einer Intel CPU Core i5-3210M mit 8 GByte RAM (PC 1). Auf diesem läuft der Algorithmus zur Fahrmanöverprädiktion. Ein zweiter PC (PC 2) dient zur parallelen Datenaufzeichnung und für Diagnosezwecke. PC 3 ist Bestandteil des Fahrerbeobachtungssystems SmartEye. An diesem PC sind die beiden Fahrerbeobachtungskameras angeschlossen und die SmartEye Software berechnet auf dem PC die Kopf- und Blickbewegungen des Fahrers. Die PCs kommunizieren miteinander über einen Router mit Ethernetverbindung. Die berechneten Werte des Algorithmus werden über eine HDMI Verbindung und einen Video Switch an die im Fahrzeug serienmäßig verbauten Bildschirme im Instrumentencluster und auf dem Navigationsbildschirm gesendet und dargestellt. Die Softwarearchitektur der Fahrmanöverprädiktion ist in Abbildung 63 dargestellt.

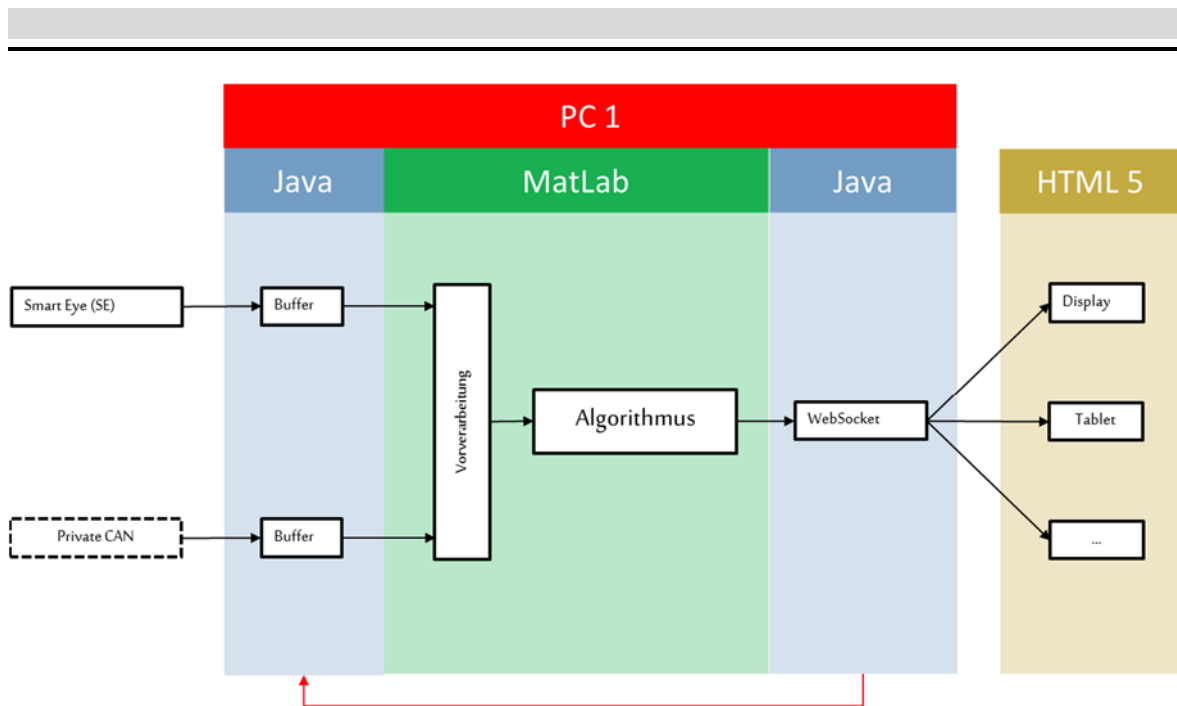


Abbildung 63: Softwarearchitektur der Fahrmanöverprädiktion im Demonstratorfahrzeug

Die entwickelten Algorithmen laufen als kompilierte MatLab Executable, eingebettet in eine Java-Umgebung. Das Java-Framework puffert die ankommenden CAN-Bus und SmartEye-Daten und stellt sie dem Algorithmus zeitsynchron in MatLab zur Verfügung. Die MatLab Executable berechnet im Schritt der Vorverarbeitung alle notwendigen abgeleiteten Signale, wie das kumulierte Blinkersignal oder das Maximum der Kopffrotation, und stellt es dem Algorithmus zur Verfügung. In diesem Schritt werden auch die Zeitstempel der Signale nochmals verglichen, um eine zeitsynchrone Verarbeitung sicherzustellen. Das ist essentiell, damit der Zusammenhang der verschiedenen Merkmale des Fahrerverhaltens zeitlich korrekt verarbeitet werden kann. Der Algorithmus berechnet aus den Daten die Manöverwahrscheinlichkeit und den zugehörigen Zeithorizont und sendet die Daten an das Java-Framework. Dieses empfängt die Daten des Algorithmus und weitere Statusinformationen und sendet alle Daten via WebSocket an eine HTML 5 Visualisierung. Die Visualisierung ermöglicht es, die Werte des Algorithmus und weitere Statusinformationen, wie die benötigte Rechenzeit je Rechenschritt, für die Analyse des Verhaltens des Algorithmus während der Fahrt grafisch darzustellen. Die Visualisierung kann in dem Demonstratorfahrzeug auf dem Infotainmentbildschirm, dem Navigationsbildschirm oder einem HTML 5 geeigneten Handy oder Tablet, welches mit dem Router im Fahrzeug über WLAN verbunden ist, dargestellt werden. Die Visualisierung ist in Abbildung 64 dargestellt.



Abbildung 64: Visualisierung der Fahrmanöverprädiktion im Demonstratorfahrzeug

Die Visualisierung stellt kein HMI zur Information des Fahrers dar, sondern dient zur Evaluierung der berechneten Daten des Algorithmus und zur Demonstration der Funktionsfähigkeit des Algorithmus.

Jedes Fahrmanöver wird in der Visualisierung als Verkehrsschild dargestellt. Das System ist im Rahmen des UR:BAN Projektes in der Lage, mehr als nur Fahrstreifenwechsel zu prädictieren und darzustellen. In Abbildung 64 ist das Verkehrsschild für den Fahrstreifenwechsel nach links zu sehen. Die Verkehrsschilder werden entlang einer Pseudo-3D Straße angezeigt. Die Größe und Transparenz der Verkehrsschilder repräsentieren die Wahrscheinlichkeit des prädictierten Fahrmanövers. Die Balkendiagramme rechts unten zeigen die Wahrscheinlichkeit für die Fahrstreifenwechsel nochmal im Detail an. Die Entfernung des Schildes entlang der Straße zum Fahrzeug repräsentiert den Zeithorizont bis zur Ausführung des Fahrmanövers (z.B. Berührung der Fahrstreifenmarkierung beim Fahrstreifenwechsel). Die Visualisierung konnte bei einer Expertenevaluierung durch die Einfachheit und Klarheit der Darstellung überzeugen, weswegen diese zur Vorführung der Leistungsfähigkeit des Algorithmus auf der öffentlichen Abschlusspräsentation des UR:BAN-Projektes genutzt wurde (vgl. auch Heine et al. im Druck).

In Abbildung 65 ist die Darstellung der Visualisierung auf dem Infotainmentbildschirm während der Fahrt dargestellt.



Abbildung 65: Darstellung der Visualisierung auf dem Infotainmentbildschirm in Echtzeit

Die Berechnungszeiten wurden bei mehreren, jeweils einstündigen, Versuchsfahrten im Realverkehr in Rüsselsheim berechnet. Während der Versuchsfahrten wurden die verschiedenen Fahrmanöver, mit Ausnahme der Notmanöver, ausgeführt.

Tabelle 19: Mittlere Rechenzeit der Algorithmen auf der Hardware im Demonstratorfahrzeug

Algorithmus		Rechenzeit
Fuzzy Logik mit Edit Distance und Datenaufbereitung	$t_{Fuzzy,comp,mean}$	0,0122s
Datenaufbereitung für Entscheidungsbaum	$t_{feature,comp,mean}$	0,0032s
2-Klassen-Entscheidungsbaum mit Regressionsbaum	$t_{2class,comp,mean}$	0,0014s
3-Klassen-Entscheidungsbaum mit Regressionsbaum	$t_{3class,comp,mean}$	0,0019s
Gesamtrechenzeit	$t_{complete,comp,mean}$	0,0173s

Die mittlere Berechnungszeit des Algorithmus mit Fuzzy Logik und Edit Distance auf Basis von Fahrzeugdaten beträgt dabei  $t_{Fuzzy,comp,mean} = 0,0122s$ , inklusive aller Berechnungen zur Datenaufbereitung, wie der Filterung von Signalen. Die Rechenzeit für den 2-Klassen-Entscheidungsbaum mit einem Regressionsbaum beträgt  $t_{2class,comp,mean} = 0,0014s$  und für den 3-

---

Klassen-Entscheidungsbaum mit Regressionsbaum  $t_{3class,comp,mean} = 0,0019s$ . Die Berechnungszeit notwendiger Merkmale, wie die Berechnung der abgeleiteten Kopfbewegungssignale, beträgt dabei im Mittel  $t_{feature,comp,mean} = 0,0032s$ . Somit beträgt die Gesamtrechnenzeit des Algorithmus mit gestacktem 3-Klassen-Entscheidungsbaum und Regressionsbaum  $t_{complete,comp,mean} = 0,0019s + 0,0032s + 0,0122s = 0,0173s$ .

Im Durchschnitt kann eine Prädiktion mit einer Updaterate von  $57Hz$  berechnet werden. Dieses bedeutet, dass die Algorithmenkonfiguration auf der verwendeten Hardware und in der Laufzeitumgebung echtzeitfähig ist, entsprechend der Forderung einer maximalen Laufzeit von  $100ms$  bzw.  $10Hz$  Updaterate.

---

## 6. Diskussion

---

In diesem Kapitel werden das Vorgehen und die Ergebnisse der vorigen Kapitel aufgegriffen und diskutiert. Zuerst wird die verwendete Methodik kritisch diskutiert (Kapitel 6.1), danach die erreichte Performance der entwickelten Algorithmen (Kapitel 6.2) und abschließend werden die Forschungsfragen adressiert (Kapitel 6.3).

### 6.1. Diskussion der Methodik

Die Diskussion der Methodik gliedert sich in die verwendete Entwicklungsmethodik bottom-up, das verwendete Entwicklungsverfahren des Wasserfallmodells, die verwendete Probandenstudie zur Datengewinnung und die Architektur des Algorithmus.

#### bottom-up

Das Verfahren der Entwicklung eines Algorithmus zur Fahrmanöverprädiktion auf Basis der Induktion hat in dieser Arbeit zu einem eingängigen Ergebnis geführt. Dazu wurden die Ziele der Entwicklung durch Analyse des Bedarfes genau definiert und mit Hilfe eines sequentiellen Entwicklungsschemas, des Wasserfallmodells, umgesetzt. Die Zielszenarien, in diesem Fall die Detektion des Fahrstreifenwechsels im städtischen Umfeld, wurden klar abgeleitet und die Datengenerierung durch eine Probandenstudie kontrolliert. Darüber hinaus eignet sich ein bottom-up Verfahren insbesondere für die hier vorgestellten und benutzten Verfahren zum Maschinernen. Maschinernen setzt bei der Synthese eines Algorithmus auf eine Datenbasis auf und kann darüber hinaus von systematischem Vorwissen unterstützt werden. Eine Synthese von Algorithmen in deduktiver Art und Weise mit top-down Methodik ist aktuell nur in begrenztem Umfang möglich. Hierbei treten eher Methoden der Verknüpfung von bekanntem Wissen zu Expertensystemen in den Vordergrund. Weiterhin hat die Mehrzahl der Maschinernenverfahren bewiesen, einen echtzeitfähigen Einsatz zu ermöglichen. Mit dem Blick auf eine mögliche Nutzung zur Verbesserung von Fahrerassistenzsystemen ist die Anforderung der Erfüllung der Echtzeitfähigkeit unbedingt einzuhalten. Bei manchen Expertensystemen oder kognitiven Architekturen ist eine Echtzeitfähigkeit derzeit, aufgrund der hohen Komplexität einer mental vollständigen Repräsentation des menschlichen Verhaltens bei der Kraftfahrzeugführung, nur schwer zu erreichen.

Die Nachteile des bottom-up Verfahrens ergeben sich ebenfalls aus den Eigenschaften. Die Ableitung von Theorien aus diesem Verfahren gestaltet sich schwierig, da die verwendeten Daten im Allgemeinen eine Einschränkung auf ein bestimmtes Szenario beinhalten oder durch menschliche Einflüsse in der Datengewinnung (Bias) mögliche aufgenommene Phänomene nicht durch Merkmale der Theorie abbildbar sind. Die Einschränkungen dieser Arbeit sind durch das bottom-up Verfahren insofern gegeben, dass nicht alle möglichen Stadtszenarien in allen verschiedenen Kombinationen eingefahren werden konnten. Festgelegt wurde eine Auswahl von Fahrstreifenwechsel auf gerader Strecke bei einer Geschwindigkeit von  $v=50\text{km/h}$  auf einer kontrollierten Teststrecke. Deshalb ist es schwierig, aus den Daten Aussagen für Fahrerverhalten bei Fahrstreifenwechsel auf Autobahnen, auf kurvigen Landstraßen oder in sehr dichtem Stadtverkehr, in dem ein sehr hohes Ablenkungspotential durch fremde Objekte besteht, abzuleiten.

Die Ergebnisse dieser Arbeit haben gezeigt, dass die Entwicklungsmethodik bottom-up in Verbindung mit einem sequentiellen Ablauf geeignet ist, aus Daten einer Probandenstudie einen Algorithmus zur Fahrmanöverprädiktion mit Fokus auf Fahrstreifenwechsel zu synthetisieren. Weitere Arbeiten, wie Sylla (2015) und Dosi (2016), haben gezeigt, dass die Nutzung dieses Algorithmus zur Prädiktion anderer Fahrmanöver, wie Anhalten an einer Kreuzung oder Notbremsen/Notausweichen, geeignet ist.

---

Schwierig gestaltet sich jedoch die Analyse der trainierten Daten zur Ableitung von allgemeingültigem Fahrerverhalten. Hierzu ist die Entwicklungsmethodik top-down, wie sie in der Arbeit von Langer (2016) zu finden ist, mit den jeweiligen Vor- und Nachteilen besser geeignet.

### **Entwicklungsmethodik**

Die Entwicklung des Algorithmus mit Hilfe eines sequentiellen Modells, in diesem Fall des Wasserfallmodells nach Royce (1970), hat zu einem annehmbaren Ergebnis geführt. Die Schritte der Entwicklung sind dabei logisch verständlich und somit durch geringen Planungsaufwand zu bewerkstelligen. Die Entwicklungsmethodik ist durch den sequentiellen Ablauf jederzeit überschaubar und die vollständigen Anforderungen an das Endprodukt sind zum Anfang des Prozesses festgelegt und für jeden weiteren Entwicklungsschritt vollständig verfügbar. Im Unterschied zu zyklischen oder iterativen Prozessen ist kein umfangreiches Versionsmanagement notwendig. Die Entwicklung fand mit einer sehr kleinen Anzahl an Personen mit dem Ziel einer prototypischen Implementierung statt, so dass der Aufwand zum Management der verteilten Arbeit gering war.

Ein Nachteil des Entwicklungsmodells ist die Inflexibilität bei sich ändernden Anforderungen. Diese sind im Prozess nicht vorgesehen. Jeder Entwicklungsschritt ist vollständig abzuschließen bevor ein weiterer Schritt angefangen werden kann, da direkt auf die Ergebnisse des vorhergehenden Schrittes aufzubauen ist. Darüber hinaus ist eine hohe Erfahrung notwendig, um mit Hilfe eines sequentiellen Prozesses erfolgreich ein Produkt zu entwickeln, da das Produkt erst sehr spät in der Entwicklungszeit für Tests zur Verfügung steht und sich somit das Risiko am Ende des Prozesses kumuliert. Weiterhin ist eine Einbindung des Nutzers schwieriger darzustellen, da der Nutzer hauptsächlich in der Definition der Anforderungen den Bedarf an dem Produkt beisteuern kann und in den Zwischenschritten vor dem Test eines nahezu fertiggestellten Produktes, keinen Einblick in die Funktion erhalten kann.

Das Entwicklungsmodell war für die Algorithmenentwicklung in dieser Arbeit geeignet, da die Anforderungen an den fertigen Algorithmus zum Anfang feststanden und sich über den Entwicklungszeitraum nicht geändert haben. Eine Vorstellung von Zwischenschritten an einem Kunden war schwer umzusetzen, da das System erst zum Zeitpunkt der Fertigstellung das Potential zur Beeinflussung von Fahrerassistenzsystemen aufzeigt und dann eine passende Zielanwendung ausgewählt werden kann. Zur Weiterentwicklung des Algorithmus bietet sich jedoch ein zyklischer Prozess oder ein agiles Verfahren, wie SCRUM an, um die Performance des Algorithmus in Abstimmung mit Funktionsentwicklern von Fahrerassistenzsystemen zu steigern, damit diese sich den notwendigen Anforderungen in iterativen Schritten nähern können, um das Risiko der Weiterentwicklung aktiv zu kontrollieren und um eine größere Anzahl an Entwicklern zu integrieren.

### **Probandenstudie & Datenanalyse**

Zur Entwicklung eines Algorithmus nach dem bottom-up Prinzip mit Hilfe von Maschinenlernverfahren war eine Probandenstudie zur Generierung von realistischem Fahrerverhalten notwendig. Die Fahrversuche wurden in einem kontrollierten Feld durchgeführt. Das führte dazu, dass das Fahrerverhalten sehr gezielt untersucht werden konnte, da inter- und intraindividuelle Unterschiede im Fahrerverhalten durch die Minimierung äußerer Störeinflüsse, beispielsweise durch andere unkontrollierte Verkehrsteilnehmer in Realfahrversuchen, besser in den Daten sichtbar wurden. Die Umgebung ist besser geeignet als eine simulierte Umgebung in Bezug auf Realismus des Fahrerverhaltens. Das Versuchsdesign und die ausgeführte Studie zeigten einen hohen Realitätsbezug, was anhand der Daten und Auswertungen in den bereits erwähnten studentischen Arbeiten aufgezeigt werden konnte (vgl. Kapitel 4). Auch das Blickverhalten hat sich durch die Darbietung eines Versuchsfahrzeuges bei der Ausführung der Fahrstreifenwechsel in der Nähe des Versuchsfahrzeuges, einem realistischen Verhalten, vergleichbar anderer Studien im Realverkehr, angenähert. Die

---

Datenqualität der Fahrzeugdaten war, bis auf einen Ausfall der Fahrstreifenerkennung bei 10 Probanden, sehr gut.

Die Datenqualität des Fahrerbeobachtungssystems in Bezug auf die Kopfbewegungen war ausreichend gut, nur die Datenqualität der Blickbewegungsanalyse lieferte aufgrund der äußeren Einflüsse und einem begrenzten Hardwaresetup mit nur 2 Kameras keine befriedigende Datenqualität. Der verwendete Bewertungsmaßstab zur Abschätzung der Eignung von Einzelprädiktoren zur Fahrmanöverprädiktion hat nach Analyse der Performance des Algorithmus zur realistischen Vorhersage der Eignung geführt. Die Informationen zur Fahrzeugposition relativ zur Fahrstreifenmarkierung haben die höchsten Einzelbewertungen erhalten und auch in der Kombination zu den besten Leistungsdaten des Algorithmus geführt. Lediglich bei Parametern mit geringerer Auftrittswahrscheinlichkeit, wie Blinker oder Schulterblick, ist das Ergebnis des Bewertungsmaßstabs nicht direkt ersichtlich, hierfür muss eine Einzelbetrachtung der Elemente, in diesem Fall der Anteil der Zeitbewertung, betrachtet werden.

Das verwendete SmartEye-System hat mit einer hohen Datenqualität Kopfbewegungsdaten robust und echtzeitfähig zur Verfügung gestellt. Durch ein nicht intrusives Messverfahren zur Bestimmung von Kopfbewegungen stellen Merkmale der Fahrerkopfbewegung für ein Fahrerassistenzsystem auch in einem Serieneinsatz nutzbare Prädiktoren dar. Denkbar wären für diesen Fall, Daten einer Fahrerbeobachtungskamera zur Müdigkeitserkennung zu nutzen, um Kopfbewegungen mit videobasierten Verfahren abzuleiten (vgl. Kapitel 2). Die Nutzung von Kopfbewegungsdaten zur Fahrmanöverprädiktion bietet das Potential, sehr frühe Merkmale bei der Fahrzeugführung zur Fahrmanöverausführung zu messen und interpretieren zu können. Dadurch kann, wie in dieser Arbeit aufgezeigt, eine Erkennung früher mit höherer Güte erreicht werden. Bleiben die Merkmale durch einen nicht ausgeführten Schulterblick des Fahrers aus, kann jedoch immer noch anhand der Fahrzeugdaten mit einer hohen Verlässlichkeit zu einem späteren Zeitpunkt ein Fahrstreifenwechsel prädiziert werden.

Dasselbe gilt für das Signal des Blinkers. Wird der Blinker vom Fahrer zur frühzeitigen Anzeige eines Fahrstreifenwechsels eingesetzt, kann eine Prädiktion ein angeschlossenes Fahrerassistenzsystem rechtzeitig aktivieren, jedoch ist auch beim Ausbleiben der Blinkernutzung vor einem Fahrstreifenwechsel eine Detektion des Fahrstreifenwechsels möglich.

Die Nachteile der kontrollierten Feldstudie waren die geringe Anzahl an salienten Fremdoobjekten, welche in einem städtischen Umfeld sehr häufig auftreten. Dadurch war das Fahrerverhalten nicht identisch mit dem Verhalten im realen Stadtverkehr. Durch die Darbietung von Notmanövern in derselben Studie zur Verwendung im UR:BAN-Projekt war die Durchführung im kontrollierten Feld jedoch unumgänglich. Auch lagen keine Fahrstreifenwechsel in Kurven vor, so dass nur Fahrstreifenwechsel auf gerader Strecke analysiert werden konnten. Die Analyse und Prädiktion von Fahrstreifenwechsel in Kurven gestaltet sich ungleich schwieriger, als auf gerader Strecke. Sie kann aber durch Anpassung der Soll-Führungsgrößen des Fahrzeuges, in Form von Straßenkrümmung und sog. Straßenlenkwinkel, adaptiv angepasst werden, um eine Erkennung in diesen Fällen zu ermöglichen (vgl. Kretschmer et al. 2006).

Weiterhin konnten die Daten der ersten Studie nicht für eine Synthese des Algorithmus zur Fahrmanöverprädiktion unter Nutzung von Kopfbewegungsdaten verwendet werden, da das verwendete Dikablis-System im verwendeten Setup keine Kopfbewegungsanalyse zuließ und darüber hinaus die Datenqualität der Blickerkennung aufgrund von äußeren Einflüssen (vor allem Sonnenlicht) qualitativ schlechter war, als die Daten des SmartEye-Systems. Weiterhin beeinflusst die Intrusivität das Fahrerverhalten hinsichtlich einer Kopfbewegung, da das System die Bewegungsfreiheit etwas einschränkt. Dadurch ist die Messtechnik für ein Serienfahrzeug aus Sichtweise der Kundenakzeptanz nicht möglich. Das SmartEye-System bestand aus 2 Kameras, wodurch der erfassbare Kopf- und Blickbewegungsbereich sehr eingeschränkt war. Die Kopfbewegungen konnten in ausreichender



---

Qualität gewonnen werden. Die Aussagen zur Eignung der Blickbewegungsdaten können, aufgrund der niedrigen Datenqualität, nicht vollständig verifiziert werden. Eventuell würden Blickbewegungsdaten höherer Qualität die Prädiktion von Fahrstreifenwechsel positiv beeinflussen, dieses konnte jedoch in dieser Arbeit nicht aufgezeigt werden. Auch die Synchronisierung von Fahrzeugdaten und Daten eines Fahrerbeobachtungssystems sollte adressiert und beachtet werden, da ein zeitlicher Versatz dieser Daten zur fehlerhaften Bewertung durch das nicht realistische zeitliche Auftreten von Merkmalen in den Daten führen kann, was die Erkennungsleistung gering und die zeitliche Prädiktion stark beeinflusst. Ebenso ist der Wertebereich des Bewertungsmaßstabs nicht optimal gewählt. So bewegen sich die verwendeten Merkmale im Bereich von  $[0.4, 0.7]$ . Es konnte nicht nachvollzogen werden, ob dieses nur auf die Eignung der getesteten Merkmale oder auf die Eigenschaften der entwickelten Formel zurückzuführen ist. Ziel des Bewertungsmaßstabs ist es valide Prädiktoren zu finden, da diese für das verwendete Abstandsmaß und den Algorithmus essentiell sind.

Zusammenfassend sind die generierten Daten nutzbar zur Synthese des Algorithmus für diese Arbeit. Das Fahrerverhalten ist mit einem Fahrerverhalten in Realfahrstudien vergleichbar, so dass die erzielten Ergebnisse auf den Realverkehr mit den vorher angesprochenen Einschränkungen, Fahrstreifenwechsel auf gerader Strecke, übertragbar sein sollten. Zur vertiefenden Analyse sollte dazu noch eine Studie im Realverkehr durchgeführt werden. Auch das positive Feedback der Experten und der teilnehmenden Probanden sowie die vergleichbaren Ergebnisse zu vorherigen Arbeiten in der Forschungslandschaft unterstützen die Hypothese der Übertragbarkeit.

Die Performance des Fahrerbeobachtungssystems ist in Bezug auf die Blickbewegungsanalyse verbesserungsbedürftig. Forschungsarbeiten im URBAN-Umfeld haben jedoch gezeigt, dass ein Setup mit mehr als zwei Kameras und eine neue Software vom Hersteller, eine deutliche Steigerung der Erkennungsleistung zulassen. Eine Verfeinerung des Bewertungsmaßstabs um ein Informationskriterium, wie beispielsweise die Entropie, wäre angemessen. Damit könnte jeder mögliche Prädiktor im Hinblick auf eine vereinte Prädiktionsleistung im Verbund eines Algorithmus besser abgeschätzt werden. Dazu sind jedoch mehrere Prädiktoren gleichzeitig zu vergleichen, was evtl. zu einem hohen Aufwand führt und dem Vorteil einer schnellen und groben Abschätzung der Eignung widerspricht. Die Ergebnisse darüber, dass sich die Blickbewegungsprädiktoren nicht zur Fahrstreifenwechselprediktion eignen, sollten auf jeden Fall unter Zuhilfenahme von Blickbewegungsdaten mit hoher Qualität überprüft werden, da die Bewertung mit Hilfe der decision stumps die Eignung als Prädiktor mit hohem Potential zur frühzeitigen Erkennung vermuten lässt. Dabei ist jedoch eine Berücksichtigung von Objekten, welche die Aufmerksamkeit unabhängig von einem geplanten Fahrmanöver ablenken, zu berücksichtigen und zu integrieren, um die SNR zu steigern.

Um Fahrstreifenwechsel besser erkennen zu können und vor allem von Kurvenfahrten und Abbiegemanövern zu unterscheiden, sollte auf die Nutzung von Straßenverlauf und digitalen Karten zurückgegriffen werden. Somit können auch Blick- bzw. Kopfbewegungen zum visuellen Verfolgen des Straßenfluchtpunktes in der Berechnung der Blickziele und Kopfdrehungen berücksichtigt werden, so dass ein Blick in einer Kurve nicht als ein Spiegelblick missinterpretiert wird. Weiterhin sollte auch betrachtet werden, dass das Vorhandensein von einem möglichen Fahrstreifen als Motivator, das Fehlen einer solchen Möglichkeit als Inhibitor, in ein System zur Fahrmanöverprediktion integriert werden sollte.

## **Diskussion Algorithmus**

Der entwickelte Algorithmus basiert auf der Theorie der Fuzzy Logik und bietet somit die Möglichkeit, menschliches Verhalten gut zu modellieren. Die Integration des Umgangs mit Zeitreihen über Zustandsautomaten wurde in der Arbeit von Bauer (2011) gezeigt. In ähnlicher Art und Weise, jedoch unter Nutzung von Verhaltenssequenzen, konnte eine Modellierung von zeitlichen Abläufen und

---

Verhalten zu einer Fahrmanöverprädiktion in dieser Arbeit umgesetzt werden. Die Verwendung eines k-Nearest-Neighbor Verfahrens hat dabei die Möglichkeit geboten, ein nicht-parametrisches Verfahren mit einer sehr niedrigen möglichen Fehlerrate einzusetzen, welche sehr nahe an eine optimale Klassifizierung heranreicht. Somit kann das während der Fahrt auftretende Fahrerverhalten direkt mit den trainierten und gespeicherten Sequenzen verglichen werden. Das Distanzmaß der Edit Distance ermöglichte, die Verhaltenssequenzen als Repräsentant des Fahrerverhaltens auch bei einer verschiedenen Länge der Sequenzen, quantitativ miteinander zu vergleichen.

Die Verwendung von offenen Designparametern ermöglicht es im Weiteren, die Performance des Algorithmus anzupassen. Das bedeutet, falls ein Algorithmus eine höhere Frühzeitigkeit erreichen soll, kann die Bewertung zugunsten der Frühzeitigkeit unter Inkaufnahme schlechterer Richtigerkennungs- oder höherer Falscherkennungsrate bevorzugt werden. Auch die Modularität bei den Eingangsgrößen ermöglicht eine Anpassung an den jeweiligen Nutzungskontext, so können für die Prädiktion von Fahrmanövern der Längsführung, wie Fahrzeug folgen oder Anhalten, andere Eingangsgrößen gewählt und der Algorithmus mit diesen trainiert werden. Das bedeutet, dass auch neue Erkenntnisse in der Forschung in Form von abgeleiteten Kennwerten als Eingangsgröße genutzt werden können, um somit die Leistung des Algorithmus auf aktuellem Stand der Forschung zu halten. Die Berechnung der Wahrscheinlichkeit aus dem Abstandsmaß hat sich als einfach und funktionell herausgestellt und ist darüber hinaus noch gut interpretierbar.

Eine Erweiterung der Trainingsdaten ist unter Konvertierung und Markierung der Trainingsdaten in das verwendete Datenformat in Matlab jederzeit möglich, allerdings ist ein neuer Trainingszyklus notwendig, da die Grenzen der Fuzzymengen und die Kosten der Edit Distance Bewertung an den vollständigen Datensatz angepasst werden. Eine zweite Erweiterung in Richtung on-line Fahreradaptivität ist ebenfalls denkbar, indem aktuelles Fahrerverhalten, nach Erkennung eines Fahrmanövers, als weitere Sequenz in der Datenbank abgespeichert wird. Dazu ist jedoch noch einige Arbeit zu leisten, da eine sehr korrekte Einordnung der Manöver vor dem Abspeichern durchgeführt werden muss und darüber hinaus die Anpassung der Kostenfunktion und Fuzzymengen aktuell nicht inkrementell erfolgen kann.

Die Markierung der Trainingsdaten für ein überwachtes Lernverfahren ist ein zeitaufwändiges Verfahren. Dieses kann teilautomatisiert werden, jedoch wurde jeder Fahrstreifenwechsel manuell überprüft, um eine hohe Konfidenz für die Trainingsdaten zu erhalten. Dieser Aufwand für die Aufbereitung von Realfahrstudien ist noch höher einzuschätzen, da hierbei auch Situationen auftreten können, welche sich nicht automatisiert einem Fahrerverhalten zuordnen lassen, somit die Trainingsdaten nicht korrekt klassifiziert sind und im Ergebnis eine Fahrmanöverprädiktion zu schlechteren Erkennungsleistungen tendiert. Weiterhin ist ein k-Nearest-Neighbor Verfahren sehr speicher- und rechenzeitintensiv, da die kompletten Trainingsdaten, im Unterschied zum parametrischen Verfahren, abgespeichert und bei der Erkennung durchsucht werden müssen. Dieser Umstand wurde in dieser Arbeit unter Verwendung des Zustandsautomaten adressiert. Der Zustandsautomat verhindert eine ständige Berechnung des Abstandsmaßes für ein Fahrmanöver durch die Aktivierungsstrategie. Dadurch kann es passieren, falls die Aktivierungsstrategie nicht gut gewählt wird, dass eventuell Fahrmanöver nicht erkannt werden oder durch vorher unbekanntes Fahrerverhalten bei der Manöverausführung, dieser zu früh deaktiviert wird. Darüber hinaus werden bei dem Verfahren zu jedem Training die Fuzzymengen aus den Daten gelernt, die Edit Distance und die Umrechnung des Distanzmaßes in die Manöverwahrscheinlichkeit berechnet. Dadurch ist das Training für ein k-Nearest-Neighbor Verfahren sehr aufwändig, das Training mit 32 Probanden auf einem Core i7 PC dauerte 15 Stunden, was zu einer Trainingszeit von 20 Tagen für eine leave-one-out-Kreuzvalidierung je Konfiguration führte. Dieses kann durch eine effizientere Umsetzung der Daten und des verwendeten Codes noch verbessert werden. Dafür wurde zur Parameteroptimierung in dieser Arbeit der Umfang der

---

Trainingsdaten reduziert, wodurch das Training jeweils nur 1 Stunde (das entspricht 9 Stunden bei der LOOCV mit 9 Probanden) dauerte.

Das Hinzufügen früher, weniger verlässlicher Prädiktoren zum Algorithmus, wie das Signal des Blinkers oder der Kopffrotation, haben zur Verschlechterung der Erkennungsleistung geführt. Die Verschlechterung ist dadurch zu erklären, dass der Algorithmus im Training Sequenzen von Zuständen mit den gewünschten Signalen trainiert. Weiterhin ist die Edit Distance ein außergewöhnliches Distanzmaß, welches ebenfalls zu der Besonderheit der Performance beitragen kann. Treten einige Merkmale nicht regelmäßig in den Ketten auf, so wird die Erkennungsleistung davon negativ beeinflusst (vgl. auch Kapitel 5.2). Somit ist die Variante des Algorithmus mit Fuzzy Logik und Edit Distance anfällig für selten auftretende Merkmale, was auch zu den Besonderheiten in der aufgezeigten Performance führt.

Eine Variante, das Verhalten zu verbessern, ist das Stacken des Algorithmus mit einem weiteren Algorithmus, welcher die weiteren Merkmale, wie Fahrerbeobachtung nutzt, um die Erkennungsleistung und Frühzeitigkeit zu verbessern. In dieser Arbeit wurden ein Entscheidungsbaum sowie ein Regressionsbaum dafür erfolgreich verwendet. Möglich ist die Kombination vieler verschiedener Algorithmen. Auch ist die Theorie des Stacken nicht die einzige Möglichkeit. Im Bereich des Ensemble Learning gibt es außerdem die Varianten des Boosting und des Bagging, um mehrere (verschiedene) Algorithmen miteinander zu verknüpfen und um eine gesteigerte Performance zu erhalten. Dabei sollten die Eigenschaften der jeweiligen Daten mit den verwendeten Algorithmen abgestimmt werden, um die bestmögliche Leistung zu erzielen. Auch ist eine sinnvolle Trennung der Daten in abhängige und unabhängige notwendig. Würde man zwei Algorithmen einsetzen und einer erkennt einen Fahrstreifenwechsel mit Hilfe des Lenkwinkels und der zweite mit Hilfe der Gierrate, ist das keine gelungene Trennung, da die Gierrate direkt vom Lenkwinkel abhängt. Eine sinnvolle Trennung wäre, dass eine Gruppe alle Daten zur Fahrzeug-Längs- und Querdynamik und je eine weitere Gruppe die Position des Fahrzeuges im eigenen Fahrstreifen, die Informationen zu relevanten Objekten in der Umgebung und die Daten zur Fahrerbeobachtung enthält. Mit dieser Aufteilung sollte mit den vorhandenen Ergebnissen eine weitere Verbesserung möglich sein.

Zusammenfassend haben sich die Auswahl und die verwendeten Algorithmen als funktional erwiesen. Die Forderungen an den Algorithmus konnten eingehalten werden. Die Fahrstreifenwechsel können mit einer Wahrscheinlichkeitsaussage vor Überfahren der Fahrstreifenmarkierung klassifiziert und der Zeithorizont präzisiert werden. Dabei repräsentiert die Fuzzy Logik das Fahrerverhalten als White-box Algorithmus. Es ist gelungen, das zeitliche Verhalten unter Nutzung von Zustandsautomaten in die Theorie der Fuzzy Logik zu integrieren. Durch die Verwendung eines k-NN Verfahrens unter Nutzung der Edit Distance als Abstandsmaß, ist die Prädiktion von Fahrerverhalten unter Berücksichtigung des inter- und intraindividuell verschiedenen Verhaltens unterschiedlicher Fahrer möglich. Auch eine Modularität in Bezug auf die Eingangsgrößen wurde erreicht, wenn auch bei einem Wechsel der Eingangsgrößen ein erneuter Trainingslauf notwendig ist. Der Algorithmus ist mit Hilfe der Designparameter konfigurierbar und an mögliche Zielassistenzsysteme anpassbar, beispielsweise für einen erwünschten Zeithorizont oder eine notwendige Fehlerkennungsrate. Er hat bei einer prototypischen Implementierung die Echtzeitfähigkeit erreicht, indem er eine Updaterate von unter 18ms auf der getesteten Hardware erzielte. Für eine finale Implementierung in eine Serienanwendung ist noch mit Hilfe einer Codeoptimierung und speziellen Anpassung an die Zielhardware eine Optimierung möglich.

---

## 6.2. Diskussion der Performance des Algorithmus

Die Parameteroptimierung hat gezeigt, dass einige Parameter wesentlichen Einfluss auf die Performance haben.

Die vorgestellte Konfiguration ist die Optimale in Bezug auf die verwendeten Trainingsdaten, wie z.B. der maximale Zeithorizont, Wissen aus dem Stand der Forschung, die Anzahl der Fuzzymengen je Eingangsgröße und ein logisches Verhältnis der Parameter und bei den Werten für die Gewichte der Edit Distance. Die Konfiguration, welche im weiteren Verlauf dieser Arbeit verwendet wird, wurde anhand eines stratified Datensatzes der Gesamtdaten am Anhaltenmanöver optimiert. Es hat sich in Stichproben gezeigt, dass diese Konfiguration auch für andere Fahrmanöver eine gute Performance erzielt, jedoch ist nicht ausgeschlossen, dass eine andere Konfiguration zu etwas besseren Ergebnissen führen kann. Da jedoch das Ermitteln einer besseren Konfiguration einen vollständigen Test im kompletten Suchraum benötigt, ist dieses sehr aufwändig. Mit Hilfe einer evolutionären Optimierung ist ein schnelleres Finden eines möglicherweise besseren Parametersatzes, sofern dieser nicht schon die optimale Konfiguration darstellt, wahrscheinlich am effizientesten umzusetzen. Die Bewertung der Leistungsdaten des Algorithmus bezieht sich auf diese, als beste ermittelte, Parameterkonfiguration.

Den größten Einfluss auf die Leistungsfähigkeit des Algorithmus zur Fahrmanöverprädiktion haben die verwendeten Eingangssignale. Wesentlich ist dabei die Eignung der Signale für eine Prädiktion des jeweiligen Fahrmanövers zu nennen (vgl. Kapitel 4.4). Die im Kapitel 5.1 verwendeten Signale stellten gemäß dem Stand der Forschung, der Bewertung gemäß des entwickelten Bewertungsmaßstabs (Kapitel 4.4) und der heuristischen Optimierung (Kapitel 5.1.8), die am besten geeigneten Signale zur Prädiktion von Fahrstreifenwechsel im vorliegenden Kontext dar. Die Basiskonfigurationen, welche in Sylla (2015) zur Parameteroptimierung vorgestellt wurden, stellen dabei jedoch noch nicht das Optimum dar. So erreichte die Konfiguration aus  $\delta; d_{lat}; TLC$  eine  $TPR = 92,48\%$  bei einer  $FPR = 6,22\%$  und eine  $AUC = 0,947$  bei einem Zeithorizont  $t_h = 0,768s$ . Dieses ist bezogen auf das Verhältnis der Richtig- und Falscherkennungsrate und der ROC Bewertung ein guter Wert, allerdings ist der Zeithorizont als eher gering einzustufen. Die zweite Basiskonfiguration mit  $\delta; d_{lat}; TLC; bl_{\Sigma}$  für den Fahrstreifenwechsel nach links erzielte eine  $TPR = 69,99\%$  bei einer  $FPR = 15,54\%$  und eine  $AUC = 0,800$  bei einem Zeithorizont  $t_h = 2,301s$ . Diese Werte sind, bezogen auf die Erkennungsraten, wesentlich schlechter, allerdings ist der Zeithorizont ein erheblich größerer, was durch die Nutzung des Signals des Blinkers zustande kommt. Dieser liefert ein sehr frühes Merkmal im Vergleich zu den weiteren fahrzeugbezogenen Daten, allerdings ist die Verlässlichkeit auf dieses Signal als gering einzuschätzen, da in den durchgeführten Versuchen nur in 75,2% bzw. 65,2% der Fälle bei einem Fahrstreifenwechsel nach links bzw. rechts der Blinker eingesetzt wurde. Daher erklärt sich auch die geringere Richtigerkennungsrate, da in den verwendeten Sequenzen der Blinker als ein wesentliches Merkmal enthalten ist.

Die in dieser Arbeit gefundenen besten Konfigurationen waren, mit Fokus auf die Daten der Fahrstreifenerkennung, folgende: Die Konfiguration mit  $d_{lat}; TLC; \alpha_{head}$  erzielte eine  $TPR = 93,69\%$  bei einer  $FPR = 3,53\%$  und eine  $AUC = 0,969$  bei einem Zeithorizont  $t_h = 0,740s$ . Diese Konfiguration liefert leicht bessere Erkennungsraten und eine etwas größere AUC bei einem vergleichbaren Zeithorizont, als die erste Basiskonfiguration.

Vor allem die sehr niedrige Fehlerkennungsrate sei hier besonders erwähnt, was bedeutet, dass von 100 zu erkennenden Manövern etwa 4 Manöver falsch und über 93 richtig erkannt werden. Wird dieser Konfiguration das Signal des Blinkers hinzugefügt ( $d_{lat}; TLC; \alpha_{head}; bl_{\Sigma}$ ), verschlechtert sich die Performance analog zur zweiten Basiskonfiguration auf eine  $TPR = 71,33\%$  bei einer  $FPR = 12,62\%$  und eine  $AUC = 0,828$  bei einem Zeithorizont  $t_h = 2,108s$ . Die Bewertung fällt hier identisch aus und ist auf die Häufig- und Frühzeitigkeit der Nutzung des Blinkers zurückzuführen.

---

In einer weiteren Konfiguration wurde die Kombination von zwei Werten der Fahrstreifenerkennung mit dem Signal des Blinkers kombiniert ( $TLC; \alpha_{head}; bl_{\Sigma}$ ) und eine  $TPR = 96,23\%$  bei einer  $FPR = 10,72\%$  und eine  $AUC = 0,950$  bei einem Zeithorizont  $t_h = 1,347s$  erreicht. Hierbei ist die hohe Richtigerkennungsrate bei einem zeitgleich hohen Prädiktionshorizont zu erwähnen. Die AUC liegt ebenfalls auf einem sehr hohen Wert, was diese Konfiguration ebenso als sehr gut auszeichnet. Diese beiden besten Konfigurationen wurden dann verwendet, um die Erkennungsleistung für den Fahrstreifenwechsel nach rechts zu bewerten. Beide Konfigurationen zeigen erwartungsgemäß eine sehr gute Performance unter Nutzung von Fahrzeugdaten. Die Konfiguration  $d_{lat}; TLC; \alpha_{head}$  erzielte eine  $TPR = 96,43\%$  bei einer  $FPR = 3,66\%$  und eine  $AUC = 0,980$  bei einem Zeithorizont  $t_h = 0,968s$  und die Konfiguration  $d_{lat}; TLC; \alpha_{head}$  erzielte eine  $TPR = 96,11\%$  bei einer  $FPR = 5,83\%$  und eine  $AUC = 0,974$  bei einem Zeithorizont  $t_h = 0,868s$ . Hier ist der Zugewinn durch Nutzung des Signals des Blinkers als gering einzuschätzen, was jedoch auf das Studiendesign zurückzuführen ist. Durch das direkte Aufeinanderfolgen der Manöverausführung des freien Fahrstreifenwechsels nach rechts, im Anschluss an den gezwungenen Fahrstreifenwechsel nach links, war die Manöर्वorbereitung für die Probanden verkürzt.

Durch die leave-one-out Kreuzvalidierung (LOOCV) wurden Eingangssignalkombinationen von Fahrzeugdaten validiert, welche eine gute Performance der Fahrmanöverprädiktion in Bezug auf die Erkennungsraten und ROC Analyse erlauben. Lediglich der Zeithorizont ist als gering einzuschätzen. Das Hinzufügen des Blinkersignals hat erwartungsgemäß den Zeithorizont deutlich gesteigert, jedoch unter Reduktion der Richtigerkennungsrate.

Um die Prädiktion des Fahrstreifenwechsels mit einem größeren Zeithorizont zu ermöglichen, wurden zum Algorithmus Daten aus der Fahrerbeobachtung als Eingangssignal hinzugefügt. Die Auswahl der wesentlichen Merkmale findet sich dabei im Kapitel 4.3, in dem der Kopfwinkel als wesentlicher Prädiktor hervorsteicht. Das Hinzufügen des Kopfwinkels zu den bisher als beste Konfigurationen herausgefundene Kombination der Eingangsdaten, lieferte mit den Signalen  $TLC; \alpha_{head}; bl_{\Sigma}; \beta_{Kopf}$  eine  $TPR = 75,85\%$  bei einer  $FPR = 21,51\%$  und eine  $AUC = 0,799$  bei einem Zeithorizont  $t_h = 2,414s$ . Hier ist eine deutliche Erhöhung des Prädiktionshorizontes zu erkennen, bei einer Verschlechterung der Erkennungsraten und der zugehörigen AUC. Die Konfiguration von  $d_{lat}; TLC; \alpha_{head}; \beta_{Kopf}$  erzielte eine  $TPR = 68,76\%$  bei einer  $FPR = 11,70\%$  und eine  $AUC = 0,816$  bei einem Zeithorizont  $t_h = 1,319s$ . Hierfür gilt dieselbe Bewertung. Auch weitere Kombinationen der Kopffrotation mit Fahrzeugsignalen liefern keine Verbesserung der Erkennungsraten, vergleichbar mit den vorigen Kombinationen wird allerdings in nahezu allen Konfigurationen ein sehr hoher Prädiktionshorizont erreicht.

In der Bewertung dieser Zahlen kommt man zu dem Schluss, dass das Signal der Kopfbewegung die Möglichkeit einer frühen Prädiktion erlauben kann, jedoch aufgrund der Häufigkeit des Auftretens bei der Manöverausführung, vergleichbar mit der Nutzung des Blinkers als Eingangssignal, zu einer Verschlechterung der Erkennungsraten beiträgt.

Weiterhin ist festzustellen, dass der Algorithmus bis zu einer Menge von drei Eingangssignalen eine gute Performance liefert. Bei der Verwendung von vier oder mehr Signalen lässt die Performance in Bezug auf die Erkennungsrate deutlich nach. Dieses ist durch die Fusion der Signale zu den Sequenzen zu erklären. Je mehr Signale zu einer Sequenz fusioniert werden, desto mehr hängt die Erkennung vom Zusammenspiel dieser Signale untereinander ab. Werden nur wenige markante Signale fusioniert, welche bei vielen Probanden in ähnlicher Abfolge auftreten, kann der verwendete Algorithmus mit hoher Zuverlässigkeit das zugrunde liegende Verhalten erkennen. Daher liefert der vorhandene Algorithmus in einer Konfiguration von 3 Eingangssignalen die beste Performance.

---

Die Erweiterung der Probandendaten von  $n = 9$  auf  $n = 32$  hat die Performance nur wenig beeinflusst. Die Konfiguration mit  $TLC; \alpha_{head}; bl_z$  erreicht dabei eine  $TPR = 98,79\%$  bei einer  $FPR = 7,34\%$  und eine  $AUC = 0,978$  bei einem Zeithorizont  $t_h = 0,906s$  bzw. in der Konfiguration mit  $d_{lat}; TLC; \alpha_{head}$  eine  $TPR = 98,45\%$  bei einer  $FPR = 4,05\%$  und eine  $AUC = 0,987$  bei einem Zeithorizont  $t_h = 0,659s$ .

Die Erkennungsraten und AUC der ersten Konfiguration sind angestiegen bei leicht reduziertem Prädiktionshorizont. Die Erkennungsrate der zweiten Konfiguration hat sich leicht verringert bei leicht erhöhtem Prädiktionshorizont.

Durch die Steigerung der verwendeten Trainingsdaten weist die gelernte Datenbank eine höhere Anzahl verschiedener Sequenzen auf und repräsentiert das inter- und intraindividuell verschiedene Verhalten der Probanden bei der Ausführung des Fahrstreifenwechsels vollständiger und ermöglicht somit eine gesteigerte Erkennungsleistung an unbekannten Testdatensätzen. Allerdings weisen die verwendeten neun Probandendatensätze bereits eine hohe Varianz und somit eine ausreichende Repräsentation individuell verschiedenen Fahrerverhaltens auf. Eine weitere Steigerung der Probandendaten auf über 32 wird voraussichtlich keinen weiteren Performanceanstieg bieten, wodurch die verwendete Anzahl an Probandendatensätzen für diese Arbeit sich als ausreichend dargestellt hat.

Zusammenfassend konnte die Eignung des entwickelten Algorithmus zur Fahrmanöverprädiktion bei der Erkennung von Fahrstreifenwechsel nachgewiesen werden. Die Performance unter Nutzung von Fahrzeugdaten bewegt sich mindestens auf dem Niveau früherer Arbeiten im Stand der Forschung. Durch die zielgerichtete Auswahl der verwendeten Merkmale und einer optimierten Parameterkonfiguration ist der Algorithmus in der Lage, Fahrstreifenwechsel erkennbar vor dem Überfahren der Fahrstreifenmarkierung durch den Fahrer zu erkennen. Der Zeithorizont ist dabei annehmbar und bewegt sich ebenfalls auf dem Niveau vorangehender Arbeiten. Durch eine vollständige leave-one-out Kreuzvalidierung an  $n = 9$  bzw.  $n = 32$  Probanden, konnte die Performance auf eine testdatenunabhängige Erkennungsleistung abgeschätzt und die Funktion validiert werden. Eine erste Implementierung in einen prototypischen Fahrzeugaufbau hat dabei gezeigt, dass der entwickelte Algorithmus Potential zur Echtzeitfähigkeit, durch die Verwendung von Zustandsautomaten zur Begrenzung der Rechenzeit, besitzt. Darüber hinaus haben die Arbeiten von Sylla (2015) und Dosi (2016) gezeigt, dass der Algorithmus zur Detektion von weiteren Manövern in der Lage ist.

Die Nachteile unter Verwendung von ausschließlich Fahrzeugdaten sind der geringe Zeithorizont. Weiterhin zeigte der Algorithmus eine Verschlechterung der Performance unter Nutzung von weniger verlässlichen, frühen Merkmalen. Der Trainingsaufwand ist in der verwendeten Implementierung unter Matlab sehr zeitaufwändig.

Somit konnte die Eignung des Algorithmus nachgewiesen und validiert werden, was einen Einsatz zur Verbesserung von Fahrerassistenzsystemen ermöglicht.

## Stacking

Zur Nutzung der Fahrerbeobachtungsdaten wurden Entscheidungsbäume als Algorithmus zur Prädiktion von Fahrstreifenwechsel betrachtet. Entscheidungsbäume, unter Nutzung von Fahrzeug- und Kopfbewegungsdaten, erreichen dabei eine Richtigerkennungsrate von nahezu 90% bei einer Fehlerkennungsrate von unter 5%. Das Hinzufügen von Blickbewegungsdaten verschlechtert die Richtigerkennungsrate auf ca. 60% bei vergleichbarer Falscherkennungsrate. Das kann an der schlechten Datenqualität der vorliegenden Blickbewegungsdaten liegen, allerdings haben andere Arbeiten ebenfalls die Überlegenheit von Kopfbewegungsdaten gegenüber Blickbewegungsdaten zur Fahrmanöverprädiktion ermittelt und herausgestellt. Eine vergleichende Bewertung der Eignung von

---

Blick- und Kopfbewegungsdaten ist aber aufgrund der Datenqualität der Blickbewegungsdaten nicht abgesichert. Dazu sollten Blickbewegungsdaten höherer Qualität herangezogen werden.

Da die Erkennungsleistung jedoch keine Verbesserung gegenüber dem Algorithmus mit Fuzzy Logik und Edit Distance geliefert hat, wurden beide Algorithmen gestackt, um die Leistungsfähigkeit der Fahrmanöverprädiktion zu steigern. Der Entscheidungsbaum, welcher zusätzlich zu den Kopfbewegungs- und einigen Fahrzeugdaten die Prädiktion des anderen Algorithmus als Eingangsdaten verwendet, erreicht sehr gute Erkennungsleistungen. Der 3-Klassen-Entscheidungsbaum erreicht eine  $TPR = 92,80\%$  bei einer  $FPR = 4,01\%$  und einem  $t_h = 2,88s$  mit einem zeitlichen Prädiktionsfehler von  $t_{h,err} = 0,56s$  für die Prädiktion des Fahrstreifenwechsels nach links und eine  $TPR = 97,92\%$  bei einer  $FPR = 3,76\%$  und einem  $t_h = 2,20s$  mit einem  $t_{h,err} = 0,76s$  beim Fahrstreifenwechsel nach rechts. Die Richtigerkennungsrate bewegt sich leicht unterhalb der Leistung der besten Konfiguration des Algorithmus aus Fuzzy Logik und Edit Distance, bei einer deutlich niedrigeren Falscherkennungsrate und einem stark erhöhten mittleren Prädiktionshorizont. Auch der zeitliche Fehler bei der Prädiktion wurde durch die Verwendung der Regressionsbäume reduziert. Die Fahrmanöverprädiktion der Fahrstreifenwechsel nach rechts beinhaltet einen geringeren Zeithorizont bei größerer zeitlicher Streuung. Dieses beruht hauptsächlich auf dem Studiendesign, das durch die Lage der Fahrstreifenwechsel nach rechts auf dem Parcours den Probanden weniger Zeit eingeräumt hat, diese Fahrstreifenwechsel vorzubereiten, wodurch die wesentlichen Merkmale später aufgetreten sind. Weiterhin ist die Varianz der Kopfbewegung bei den Fahrstreifenwechseln nach rechts höher (Achieser 2016) und somit die größere Varianz der zeitlichen Prädiktion zu erklären.

Die Einflussanalyse der einzelnen Prädiktoren hat dabei ergeben, dass die berechnete Wahrscheinlichkeit des Algorithmus mit Fuzzy Logik und Edit Distance den größten Einfluss auf das Ergebnis hat. Dieses unterstützt die Bewertung, dass der Algorithmus eine gute Performance liefert, aber durch die Verwendung von Kopfbewegungsdaten mit Hilfe der Entscheidungsbäume verbessert werden kann.

Die Möglichkeit der Nutzung der Fahrerkopfbewegung zur Verbesserung einer Fahrmanöverprädiktion stellt ein gutes Ergebnis dar. Die Kopfbewegungsdaten besitzen ein besseres SNR im Vergleich zu Blickbewegungsdaten. Die Gefahr einer salienten Ablenkung der Kopfrichtung ist als geringer einzuschätzen, wenn der Fokus des Fahrers auf der Fahrzeugführung liegt. Das kann zwei Gründe haben. Zum einen kann die Ablenkung des Blickes durch unwesentliche Elemente für die Fahrzeugführung, aufgrund der höheren möglichen Blickbewegungsgeschwindigkeit, schneller ablaufen. Zum anderen ist eine geringere Muskelaktivität für eine Blickbewegung, im Vergleich zur Kopfrotation, notwendig, wodurch das Signal der Kopfbewegung weniger anfällig für diese Art der Ablenkung ist. Daher ist das Signal der Kopfbewegung in Bezug auf diese Bewegungen mit einem höheren SNR ausgestattet und somit als validerer Parameter zu betrachten (Doshi und Trivedi 2009b). Weiterhin ist die Kopfbewegungsanalyse mit geringerem Hardwareaufwand, einer Monokamera, bei gleichzeitig weniger Rechenleistung zur Auswertung realisierbar und erzielt dabei eine bessere Erkennungsqualität als eine Blickdatenanalyse. Monokameras sind z.T. bereits seit einigen Jahren in der Serie verfügbar bzw. werden in naher Zukunft von vielen Herstellern mit dem Fokus auf Erkennung von Müdigkeit und Ablenkung angeboten. Diese Hardware kann dann zur Erkennung der Kopfbewegung für eine Fahrmanöverprädiktion herangezogen werden, wodurch der notwendige zusätzliche Hardwareaufwand für die Erkennung der wesentlichen Merkmale für die Verbesserung einer Fahrmanöverprädiktion merklich sinkt.

Durch das Stacken der Algorithmen konnte die Erkennungsleistung verbessert werden. Der mittlere Zeithorizont der Prädiktion und der mittlere Fehler der Zeitprädiktion haben die Performance des entwickelten Algorithmus mit Fuzzy Logik und Edit Distance nochmals gesteigert. Durch die Erweiterung sind nun auch weniger verlässliche Merkmale, wie Daten zur Fahrerbeobachtung,

---

integrierbar. Die Rechenzeit ist durch die Verwendung von Entscheidungs- und Regressionsbäumen in einer prototypischen Implementierung kaum angestiegen und verspricht weiterhin eine Erfüllung der Echtzeitanforderungen. Nachteilig ist hierbei, wie bei allen Verfahren des Ensemble Learning, das mehrstufige Training und der somit noch weiter gestiegene Aufwand.

Die Erkennungsleistung der verwendeten gestackten Algorithmen liegt mindestens auf dem Niveau bisheriger Algorithmen zur Fahrmanöverprädiktion für Fahrstreifenwechsel. Eine genaue Einordnung ist jedoch aufgrund der unterschiedlich angesetzten Leistungsmerkmale und Manöverdefinitionen schwer herzustellen. Die geringe Fehlerkennungsrate verspricht, in Verbindung mit einem angeschlossenen Fahrerassistenzsystem, das Warndilemma abzuschwächen. Der mittlere Zeithorizont ist so groß, dass Fahrerwarnungen rechtzeitig dem Fahrer präsentiert werden können, damit dieser noch vor Überfahren der Fahrstreifenmarkierung im Fall einer bevorstehenden Kollision, rechtzeitig selbstständig eingreifen kann, um diese zu verhindern. Der entwickelte Algorithmus hat somit das Potential, Fahrerassistenzsysteme nachhaltig zu verbessern und einen Beitrag zur Steigerung der Sicherheit im Straßenverkehr zu liefern.

### **6.3. Diskussion der abgeleiteten Forschungsaufgabenstellung**

Im Folgenden werden die formulierten Aufgaben anhand der erreichten Ziele beantwortet:

- Auswahl eines geeigneten Prozesses zur Entwicklung eines Algorithmus zur Fahrmanöverprädiktion mit dem Fokus auf inter- und intraindividuelles Fahrerverhalten beim Fahrstreifenwechsel

Die Auswahl eines sequentiellen Entwicklungsprozesses im Rahmen einer induktiven Entwicklung hat diese unterstützt und positiv beeinflusst. Getrieben durch die stabilen Anforderungen konnte sich das Modell behaupten und hat zu einem annehmbaren Ergebnis geführt. Die Fokussierung auf inter- und intraindividuelles Fahrerverhalten konnte durch die ausgeführte Probandenstudie und der Wahl des Algorithmus realisiert werden.

- Entwicklung eines Algorithmus zur Fahrmanöverprädiktion mit dem Ziel der Fahrstreifenwechselprediktion im innerstädtischen Verkehr entlang des ausgewählten Prozesses:

Der entwickelte Algorithmus auf Basis von Fuzzy Logik und Edit Distance ist in der Lage, Fahrerverhalten zur Fahrmanöverprädiktion zu modellieren und Fahrstreifenwechsel mit Hilfe von Fahrzeugdaten mit einer hohen Klassifikationsgüte, noch bevor das Fahrzeug die Fahrstreifenmarkierung überfährt, zu präzisieren.

- Definition und Bewertung wesentlicher Merkmale des Algorithmus

Die Auswahl und die Merkmalsextraktion mit der Konzentration auf bekannte und nachgewiesen geeignete Prädiktoren haben zu der dargestellten Leistungsfähigkeit geführt. Der Algorithmus hat im Rahmen der Analyse sein Potential bewiesen, was rückschließend die richtige Auswahl und Festlegung der Merkmale bestätigt.

- Datensammlung natürlichen Fahrerverhaltens für die Synthese des Algorithmus

Das Studiendesign, der abschließende Test im freien Straßenverkehr und die gezeigte Performance deuten auf eine hohe Eignung der gesammelten Daten zur Repräsentation der Anforderungen hin.

- Auswahl geeigneter Eingangsgrößen für den Algorithmus anhand einer quantitativen Metrik



---

Die beschriebenen Merkmale zur relativen Positionierung des Fahrzeuges im Fahrstreifen und zu Bedientätigkeiten, wie der Lenkwinkel, eignen sich für eine Fahrmanöverprädiktion. Mit Hilfe des Bewertungsmaßstabs lassen sich geeignete Prädiktoren für ein gewünschtes, zu prädizierendes Fahrmanöver identifizieren. Eine Auswahl wurde im Kapitel 4.4 getroffen und im Kapitel 5.1, in Verbindung mit der leave-one-out Kreuzvalidierung, validiert. Zur Steigerung des Prädiktionshorizontes können Merkmale, welche unzuverlässiger, aber früher im Verlauf der Manöverausführung auftreten, hinzugefügt werden. Dadurch kann der Prädiktionshorizont bei geringfügig reduzierter Erkennungsleistung vergrößert werden.

- Synthese des Algorithmus unter Nutzung der gesammelten Daten mit dem Ziel einer Fahrmanöverprädiktion

Der Algorithmus hat im Rahmen der Validierung und Implementierung in das Demonstratorfahrzeug das Potential und die Leistungsfähigkeit zur Fahrmanöverprädiktion bewiesen und sein Potential für den realen Straßenverkehr angedeutet.

- Validierung des Algorithmus mit Hilfe eines geeigneten Verfahrens

Das LOOCV Verfahren hat als etabliertes Verfahren im Rahmen der Bewertung von Algorithmen die Leistungsfähigkeit des Algorithmus validiert und das Potential des Algorithmus fundiert bewertet.

- Prototypische Implementierung und Test des Algorithmus in ein Fahrzeug

Die Implementierung und die Darstellung der Echtzeitfähigkeit in diesem Setup haben dargestellt, dass der entwickelte Algorithmus die gestellten Anforderungen erreicht. Eine Weiterentwicklung zu einem seriennahen Algorithmus für einen zukünftigen Serieneinsatz scheint möglich.

- Bewertung und Einordnung der Ergebnisse in den Forschungskontext:

Die Leistungsfähigkeit des Algorithmus und der Implementierung zeigt das Potential der entwickelten Lösung auf und ermöglicht es, Fahrerassistenzsystemen zusätzliche Informationen zur Fahrerabsicht bereitzustellen. Die Umsetzung in ein Demonstratorfahrzeug zeigt dabei, dass der Algorithmus bereits einen Reifegrad besitzt, um diese Verbesserungen in naher Zukunft nutzen zu können.

- Besitzt der Algorithmus das Potential die angestrebten Verbesserungen von Fahrerassistenzsystemen zu erreichen

Durch die Nutzung von Fahrerbeobachtungsdaten und einer Erweiterung des entwickelten Algorithmus um Entscheidungs- und Regressionsbäume (Kapitel 5.2) können Prädiktionshorizonte von im Mittel über 2 Sekunden, unter Einbehaltung der Echtzeitfähigkeit erreicht werden. Somit erhöhen Fahrerbeobachtungsdaten die Performance deutlich und erreichen einen klaren Gewinn gegenüber der Prädiktion ausschließlich mit Fahrzeugdaten. Durch diese mittleren Prädiktionshorizonte von über 2 Sekunden und einer relativ geringen Fehlerkennungsrate von unter 4% besteht das Potential, warnenden Fahrerassistenzsystemen die notwendige Fahrerinformation rechtzeitig (vgl. auch Naujoks et al. 2012) mit einer hohen Richtigerkennungsrate präsentieren zu können. Die geringe Fehlerkennungsrate erlaubt, ein möglich auftretendes Warndilemma, im Vergleich zu einem Fahrerassistenzsystem ohne Fahrmanöverprädiktion, gering zu halten.

---

## 7. Fazit und Ausblick

---

In diesem Kapitel wird die Arbeit zusammengefasst und ein Fazit gezogen (Kapitel 7.1). Weiterhin wird ein Ausblick gegeben (Kapitel 7.2) und mögliche Anwendungsfälle (Kapitel 7.2.1) sowie der weitere Forschungsbedarf (Kapitel 7.2.2) werden aufgezeigt.

### 7.1. Fazit

Das Ziel dieser Arbeit war, einen Algorithmus zur Fahrmanöverprädiktion von Fahrstreifenwechsel im Stadtverkehr zu entwickeln und zu evaluieren. Dabei sollten Daten einer Probandenstudie genutzt werden, um diesen Algorithmus nach der bottom-up Methodik mit Hilfe des Wasserfall Entwicklungsmodells zu entwickeln. Dabei wurden auf Fahrzeug- und Fahrerbeobachtungsdaten zurückgegriffen und ein echtzeitfähiger Algorithmus zur Fahrmanöverprädiktion entwickelt, validiert und prototypisch implementiert.

Die verwendete Entwicklungsmethodik (Kapitel 3.1) nach dem bottom-up Verfahren hat in dieser Arbeit gezeigt, dass eine zielgerichtete Entwicklung eines Algorithmus zur Fahrmanöverprädiktion mit dieser Herangehensweise möglich ist. Das sequentielle Wasserfallmodell bietet dabei den Rahmen, die jeweiligen Entwicklungsschritte erfolgreich zu moderieren. Der entwickelte Algorithmus (Kapitel 5.1) ist tauglich, Fahrstreifenwechsel bei städtischen Geschwindigkeiten mit Hilfe von Daten einer Probandenstudie (Kapitel 4.1) zu prädictieren. Dabei ist der Umgang des Algorithmus mit inter- und intraindividuell verschiedenem Fahrerverhalten, durch die Nutzung der Methoden der Fuzzy Logik und des Edit Distance Distanzmaßes, gut möglich.

Der Algorithmus zeigt unter Nutzung einer Auswahl von geeigneten Prädiktoren mit Fahrzeugdaten (Kapitel 4.4), eine gute Erkennungsleistung mit einer geringen Fehlerkennungsleistung bei einem moderaten Zeithorizont der Prädiktion (Kapitel 5.1.9). Die direkte Integration von Fahrerbeobachtungsdaten (Kapitel 4.3) in denselben Algorithmus hat die Performance verschlechtert (Kapitel 5.2), aber durch das Stacken des entwickelten Algorithmus mit Entscheidungs- und Regressionsbäumen (Kapitel 5.2.1) konnte die Erkennungsleistung verbessert und die zeitliche Prädiktion stark verbessert werden (Kapitel 5.2.2). Durch eine prototypische Implementierung in ein Demonstratorfahrzeug konnte die Echtzeitfähigkeit der Algorithmenstruktur aufgezeigt werden. Die gesetzten Ziele dieser Arbeit konnten damit erfüllt werden, jedoch bleibt weiterer Forschungsbedarf bestehen.

### 7.2. Ausblick

Die Entwicklung des Algorithmus ist nach der Bewertung der Leistungsdaten und der in der Diskussion aufgezählten Eigenschaften (Kapitel 6.1) noch nicht abgeschlossen. Der Umgang des Algorithmus mit mehreren Eingangsgrößen sollte untersucht werden. Dabei wäre eine Möglichkeit, das Verfahren zur Bootstrap Aggregation aus der Gruppe des Ensemble Learning zu verwenden, um mehrere identische Algorithmen mit verschiedenen Eingangsgrößen parallel einzusetzen und eine Fahrmanöverprädiktion mit Hilfe einer Metaklassifizierung der Ergebnisse der Algorithmen der unteren Schicht zu bestimmen (Bagging). Damit könnte das Problem der nicht zuverlässig auftretenden Merkmale, wenn diese jeweils in unabhängigen Algorithmen betrachtet werden, adressiert werden. Somit scheint eine Eignung des entwickelten Algorithmus für Merkmale verschiedener Quellen möglich.

Weiterhin sollte der Algorithmus für alle Fahrmanöver, mit jeweils eigenem Zustandsautomaten, trainiert werden. Diese Algorithmen sollten dann ebenfalls mit der Methode der Bootstrap Aggregation

---

verbunden werden, da durch die positive Erkennung anderer Fahrmanöver, die Fehlerkennungsrate des Fahrstreifenwechsels verbessert werden kann.

Auch eine Weiterentwicklung zu einem adaptiven System birgt das Potential, die Erkennungsleistung zu verbessern. Dabei wird ein vom Fahrer absolviertes und als positiv erkanntes Fahrmanöver gem. den trainierten Fuzzymengen zu einer Fahrmanöversequenz transformiert und zusätzlich in der Manöverdatenbank abgelegt. Eine Optimierung der Kostenfunktion oder sogar von Fuzzymengen ist jedoch online nicht möglich und auch eine funktionierende Manövererkennung als Basis der Entscheidung, ein gezeigtes Verhalten einem Fahrmanöver zuzuordnen, ist dabei unerlässlich.

Dazu wäre auch eine Analyse von Fahrstreifenwechsel in Kurven angebracht. Eine Anpassung der verwendeten Prädiktoren kann sinnvoll werden, indem anstelle des Lenkwinkels der Wert der Abweichung des aktuellen Lenkwinkels vom Lenkwinkel zum Folgen der kurvigen Straße verwendet wird. Auch die Nutzung weiterer Signale aus Eingangsgrößen kann die Performance steigern. In anderen Arbeiten haben sich Umfeldinformationen von anderen Fahrzeugen als früher Prädiktor, beispielsweise für eine Überholabsicht, gezeigt. Die Modellierung dieser Motivatoren, wie ein langsamer Vorfahrer und Inhibitoren, wenn kein Zielfahrstreifen für einen Fahrstreifenwechsel zur Verfügung steht, bieten die Chance einer weiteren Verbesserung der Erkennungsleistung. Diese Verbesserungen sollten dann anhand einer Realfahrstudie, möglicherweise einer Sekundärdatenanalyse vorhandener Fahrversuchsdaten, überprüft und validiert werden.

#### **7.2.1.1. Mögliche Anwendungsfälle**

Der entwickelte Algorithmus zur Fahrmanöverprädiktion hat gezeigt, dass eine Manöverprädiktion unter Nutzung von Fahrerbeobachtungsdaten im Mittel 2,5s vor Berühren der entsprechenden Fahrstreifenmarkierung möglich ist. Im Kapitel 2.2 wurde als Gestaltungshinweis für eine effektive Warnung zwei bis drei Sekunden vor einem notwendigen Eingriff durch den Fahrer im städtischen Umfeld angegeben. Somit bietet der entwickelte Algorithmus die Leistungsfähigkeit zur Verbesserung von Fahrerassistenzsystemen.

Aktuelle Spurverlassenswarner (LDW) nutzen zur Erkennung einer Fahrerabsicht die Betätigung des Blinkerhebels. Wird dieser beim Überfahren der Fahrstreifenmarkierung nicht aktiviert, wird der Fahrer im Falle eines unterlassenen Blinkens beim Fahrstreifenwechsel zu Unrecht gewarnt. Der Algorithmus zur Fahrstreifenwechselprädiktion kann auch ohne die Verwendung des Blinkers eine Fahrerabsicht zum Fahrstreifenwechsel erkennen und in diesem Fall eine Unterdrückung, der diesbezüglich nicht notwendigen Warnung, veranlassen. Im Falle eines unbeabsichtigten Spurverlassens könnte jedoch die Warnung zum Überschreiten der Fahrstreifenmarkierung zeitlich vor dem Überfahren angezeigt werden, damit der Fahrer mehr Zeit zur Reaktion und Abwendung eines unabsichtlichen Spurverlassens hat. Dazu ist allerdings eine gute Unterscheidung von Fahrstreifenwechsel und unbeabsichtigtem Spurverlassen wesentlich.

Assistenzsysteme zur Spurhaltung (LKA) bieten ebenfalls Möglichkeiten zur Verbesserung. Wenn diese nicht in einer kontinuierlichen Querführung, sondern in einer späten, ein unabsichtliches Überfahren der Fahrstreifenmarkierung verhindernden Auslegung konfiguriert sind, kann die Erkennung der Fahrerabsicht zu einem Fahrstreifenwechsel ohne Betätigung des Blinkers die Abschaltung des Lenkmoments zur Spurhaltung aktivieren. Dies hätte den Vorteil, einem Fahrer beim Fahrstreifenwechsel ohne Blinkeraktivierung kein Gegenmoment vor dem Überfahren der Fahrstreifenmarkierung anzubieten.

Auch zur Verbesserung eines Totwinkelwarners, in Form eines Spurwechselassistenten, ist der Einsatz dieser Fahrmanöverprädiktion möglich. Beim Erkennen einer Fahrstreifenwechselabsicht mit einer genügend hohen Wahrscheinlichkeit kann eine Warnung zu einem belegten toten Winkel durch einen

---

anderen Verkehrsteilnehmer früher, vor dem Überfahren der Fahrstreifenmarkierung, auch ohne Aktivierung des Blinkers präsentiert werden. Ebenso kann im Fall einer gesicherten Erkennung, dass der Fahrer keinen Fahrstreifenwechsel plant, eine Information über die Belegung des toten Winkels abgeschwächt oder vollständig unterdrückt werden.

Die aufgezeigten möglichen Einsatzbereiche einer Fahrstreifenwechselprädiktion bieten das Potential die erwähnten Fahrerassistenzsysteme zu verbessern, indem die vom Fahrer als unnötig angesehenen Warnungen abgeschwächt oder unterdrückt werden können. Notwendige Warnungen können früher präsentiert oder in der Modalität verstärkt werden. Dabei sollte jedoch dem Fahrer bei jeder unterdrückten oder abgeschwächten Warnung eine Information dargeboten werden, die ihm anzeigt, dass durch die Fahrmanöverprädiktion eine vom Assistenzsystem gewünschte Warnung unterdrückt wurde. Dieses sollte in einer, im Vergleich zur Warnung, abgeschwächten Modalität geschehen. Dem Fahrer kann es helfen, die Funktionsweise des Assistenzsystems besser zu verstehen und unterstützen, die Systemgrenzen, in denen er sich auf das System verlassen kann, auszuloten. Andernfalls kann eine zeitweise Unterdrückung von Warnungen zu einem verminderten Systemverständnis führen und möglicherweise den gegenteiligen Effekt haben, dass das Fahrerassistenzsystem aus Unverständnis abgeschaltet wird. Diese Maßnahmen können in Summe zu einer Akzeptanzsteigerung bei verringertem Warndilemma führen und den Einsatz von Fahrerassistenzsystemen erhöhen, was eine Reduktion von Unfallzahlen positiv beeinflussen kann.

### **7.2.2. Weiterer Forschungsbedarf**

Über die vorgestellte Arbeit hinaus besteht weiterer Forschungsbedarf. Die Fahrmanöverprädiktion sollte mit Zielassistenzsystemen verknüpft werden, um die Funktion und die möglichen Verbesserungen testen zu können. Dazu wäre es sinnvoll, den Algorithmus zur Fahrstreifenwechselprädiktion in ein Fahrzeug mit möglichen Zielassistenzsystemen zu integrieren und die Assistenzsysteme zur Nutzung dieser Informationen zu adaptieren. Eine Probandenstudie, möglichst im Realverkehr, mit einem Vergleich der Assistenzsysteme mit und ohne Verbesserung durch Fahrmanöverprädiktion, ermöglicht eine Akzeptanzbewertung für ein System zur Fahrmanöverprädiktion und bietet weiterhin die Möglichkeit, Fahrerverhalten im Realverkehr zum Test und zur Weiterentwicklung des Algorithmus zu erhalten. Dazu sollte die Studie möglichst viele unterschiedliche Verkehrssituationen abdecken, um eine große Datenbasis zur Auswertung für eine realistische Potentialbewertung zu erhalten.

Der Einsatz eines verbesserten Systems zur Blickbewegungserkennung durch mehr Kameras oder verbesserte Software kann ebenfalls weitere Daten liefern, um eine Eignung von Merkmalen zur Blickbewegung in Bezug auf die Fahrmanöverprädiktion abzuschätzen und zu testen. Auch ein Test weiterer abgeleiteter Merkmale als Prädiktoren sollte beim Gewinnen von neuen Erkenntnissen und zur Integration in den Algorithmus berücksichtigt werden.

Die Realfahrstudie sollte darüber hinaus auch Fahrstreifenwechsel in Kurvenfahrten und deutlich belebtere Situationen in Innenstädten beinhalten, um den Algorithmus unter schwierigen realen Bedingungen in Verbindung mit einem hoch veränderlichen Umfeld testen zu können. Das Blick- und Kopfbewegungsverhalten kann in einem Umfeld mit hohem Ablenkungspotential sehr unterschiedlich zu dem Verhalten in der durchgeführten Studie sein. Dazu sollte ein System zur Detektion und Bewertung von fahrrelevanten Objekten implementiert und mit den Blickbewegungen des Fahrers abgeglichen werden. Somit besteht die Möglichkeit, relevante Blickbewegungen von Blickbewegungen durch saliente Ablenkung zu unterscheiden und das Blickverhalten als valideren Prädiktor einsetzen zu können.

In der ausgeführten Studie wurde versucht, die Ablenkung und Müdigkeit der Probanden möglichst konstant zu halten. Weitere Forschung sollte auch die Einflüsse dieser Faktoren auf die Fahrmanöverausrückung untersuchen, indem diese Werte gezielt variiert werden, um Daten von

---

abgelenkten oder müden Fahrern zu erhalten und um diesen, in einer weiteren Entwicklung, die größtmögliche Unterstützung anbieten zu können.

Ein Ansatz der Nutzung von Fahrerverhaltensprädiktion könnte auch im Umfeld von automatisiertem Fahren eingesetzt werden. Beispielsweise kann anhand von gewissem Fahrerblickverhalten der Wunsch eines Fahrstreifenwechsels, bei langsamen Vorfahrern, abgeleitet werden, so dass eine automatisierte Funktion diesen Fahrstreifenwechsel zum nächstmöglichen Zeitpunkt ausführt. Dafür ist jedoch eine komplette Studie mit der Analyse von Fahrerverhalten beim automatisierten Fahren notwendig, da sich die Merkmale vom manuellen Fahren deutlich unterscheiden werden. Es können keine Lenksignale oder Pedalbedienungen des Fahrers zur Prädiktion herangezogen werden und das Blickverhalten bei einer automatisierten Fahrzeugführung wird sich wesentlich vom manuellen Fahren unterscheiden.

Diese Erkenntnisse sollten dann genutzt werden um die Weiterentwicklung des Algorithmus voranzutreiben, die Leistungsfähigkeit weiter zu erhöhen und um einen möglichen Serieneinsatz zu ermöglichen.

### Abbildungsverzeichnis

Abbildung 1: Schematische Darstellung von Deduktion und Induktion zur Fahrermodellierung .....	4
Abbildung 2: Kombination des Skill-Rule-Knowledge- und Fahrer-Fahrzeug-Umwelt-Modells (Donges 2015) .....	10
Abbildung 3: Rubikon Modell aus Diederichs (2016), angelehnt an Heckhausen und Gollwitzer (1987) .....	11
Abbildung 4: Beispielabbildung eines künstlichen Neuronalen Netzes (Bishop 2006).....	25
Abbildung 5: Aufbau eines Fuzzy Logik Systems .....	26
Abbildung 6: Schematische Darstellung rekurrenter Fuzzy Logik Systeme.....	28
Abbildung 7: Schematische Funktionsraumdarstellung eines 5-Nearest-Neighbor-Verfahrens zur Klassifizierung des unbekannten Elementes y .....	29
Abbildung 8: Beispiel für Entscheidungsbäume: Eingangsdatendimension (links) und grafische Struktur (rechts) aus Bishop (2006) .....	31
Abbildung 9: Kategorisierung von Merkmalen angelehnt an Donges (1982) .....	32
Abbildung 10: Fiktives Beispiel einer ROC-Kurve aus Sylla (2015) .....	38
Abbildung 11: Wasserfallmodell nach Royce (1970) .....	43
Abbildung 12: Vollständiger Wasserfallprozess nach Royce (1970).....	44
Abbildung 13: Versuchsfahrzeug Opel Insignia Modelljahr 2012.....	62
Abbildung 14: Beispielhafte Integration eines SmartEye Fahrerbeobachtungssystems .....	63
Abbildung 15: Blickziele (Areas of interest, AOI) des Fahrerbeobachtungssystems .....	64
Abbildung 16: Schematischer Aufbau der Versuchsstrecke für die Probandenstudie .....	65
Abbildung 17: Schematische Darstellung "freier" Fahrstreifenwechsel nach rechts (Langer et al. 2016) .....	67
Abbildung 18: Schematische Darstellung "gezwungener" Fahrstreifenwechsel nach links (Langer et al. 2016) .....	67
Abbildung 19: Foto des Versuchsaufbaus "freier" Fahrstreifenwechsel nach links .....	68
Abbildung 20: Foto des Versuchsaufbaus "gezwungener" Fahrstreifenwechsel nach links .....	68
Abbildung 21: Darstellung und Sichtbarkeit der Positionen des weiteren Fahrzeuges während der Studie .....	70
Abbildung 22: Durchschnittliche Fahrleistung der Probanden (Langer et al. 2016).....	71
Abbildung 23: Fahrstil, Selbsteinschätzung der Probanden (Langer et al. 2016) .....	71

Abbildung 24: Trajektorienverlauf aller Probanden beim Fahrstreifenwechsel nach links mit interindividuellen Unterschieden .....	72
Abbildung 25: Trajektorienverlauf eines Probanden beim Fahrstreifenwechsel nach links mit intraindividuellen Unterschieden .....	72
Abbildung 26: Detektionsqualität des SmartEye Systems bezüglich Blickbewegungs- und Kopfbewegungserkennung.....	73
Abbildung 27: Verteilung der Spiegelblicke vor Fahrstreifenwechsel nach links in der Probandenstudie (Langer et al. 2016) .....	74
Abbildung 28: Blickhäufigkeiten in die Außen- und Rückspiegel vor den Fahrstreifenwechseln (Langer et al. 2016).....	75
Abbildung 29: Zeitliche Verteilung der Blinkeraktivierung beim Fahrstreifenwechsel (vgl. Schmidt et al. 2014).....	76
Abbildung 30: Verlauf des Lenkwinkels während der Fahrstreifenwechsel und Wahl der Analysegrenzen aus Achieser (2016).....	80
Abbildung 31: Zeitlicher Verlauf des Lenkwinkels aller Probanden vor einem Fahrstreifenwechsel nach links.....	86
Abbildung 32: Verteilung des Lenkwinkels aller Probanden beim Fahrstreifenwechsel nach links zum Zeitpunkt $t = -5,5s$ .....	87
Abbildung 33: Grafische Darstellung des Friedman-Tests zur Bestimmung des Zeitpunktes $t^*$ .....	88
Abbildung 34: Darstellung der Verteilung des Lenkwinkels zu den Zeitpunkten $t = -5,5s$ und $t = t^*$ in Relation zu dem zeitlichen Verlauf des Lenkwinkels .....	89
Abbildung 35: Verteilung des Lenkwinkels beim Fahrstreifenwechsel nach links zum Zeitpunkt $t^*$ und Darstellung des Value-of-interest (VOI).....	89
Abbildung 36: Zeitliche Häufigkeitsverteilung des Erreichens von <i>Lenkwinkel</i> = <i>VOI</i> beim Fahrstreifenwechsel nach links .....	90
Abbildung 37: Darstellung der Lage von $t^*$ , 5-/95-Perzentil und VOI im zeitlichen Verlauf des Lenkwinkels beim Fahrstreifenwechsel nach links.....	91
Abbildung 38: Verlauf der Sigmoidfunktion zur Bewertung der Zeit im Vergleich zu einer Rampenfunktion unter Berücksichtigung von $t_{\max}$ .....	92
Abbildung 39: Schematische Darstellung für die Erkennungsfälle richtig positiv, richtig negativ, falsch positiv und falsch negativ anhand eines fiktiven Signalverlaufes und VOI.....	92
Abbildung 40: Ablaufschema des Algorithmus .....	98
Abbildung 41: Fuzzifizierung der Eingangsdaten am Beispiel des Lenkwinkels beim Fahrstreifenwechsel nach links .....	100
Abbildung 42: Beispiel des Parameters Fuzziness anhand zweier Trapez-Zugehörigkeitsfunktionen	101
Abbildung 43: Schematische Darstellung einer Fahrerverhaltenssequenz .....	103

Abbildung 44: Beispiel eines Fahrstreifenwechsels nach links mit Lenkwinkel (oben), TLC (Mitte) und kumuliertes Blinksignal (unten) sowie der entsprechenden Zustandskette.....	103
Abbildung 45: Beispiel drei verschiedener Fahrerhaltenssequenzen.....	104
Abbildung 46: Beispiel eines Zustandsautomaten generiert aus den Fahrerhaltenssequenzen in Abbildung 45.....	104
Abbildung 47: Beispiel zweier ähnlicher Fahrerhaltenssequenzen.....	105
Abbildung 48: Beispiel einer Fahrerhaltenssequenz zum Vergleich mit Abbildung 47.....	106
Abbildung 49: Beispiel zur Reihenfolge der Transitionen für die Edit Distance.....	107
Abbildung 50: Zuordnung des Gesamtabstands $d\Sigma$ auf die Wahrscheinlichkeit $p$ .....	110
Abbildung 51: Zuordnung des Gesamtabstands $d\Sigma$ auf den Zeithorizont $th$ .....	111
Abbildung 52: ROC-Kurve.....	115
Abbildung 53: Bewertung von TPR, FPR und $th$ .....	116
Abbildung 54: Entscheidungsschwelle in Bezug zu Wahrscheinlichkeits- und Zeithorizontverlauf der Prädiktion.....	117
Abbildung 55: Leistungsfähigkeit des Entscheidungsbaumes ohne Kombination mit dem im Kapitel 5.1 gezeigten Algorithmus als Vergleichsmaßstab mit Kopfbewegungsdaten (links) und Kopf- und Blickbewegungsdaten (rechts).....	123
Abbildung 56: Schematische Darstellung des Algorithmus Stacking (Foto SmartEye Kamera von Smart Eye AB (2015)).....	124
Abbildung 57: Leistungsfähigkeit des Entscheidungsbaumes mit Kopfbewegungsdaten ohne (links) und mit Stacking (rechts).....	124
Abbildung 58: Darstellung der relevantesten Eingangssignale des Entscheidungsbaumes anhand der Feature Importance.....	125
Abbildung 59: Leistungsfähigkeit des 3-Klassen Entscheidungsbaumes mit reduzierten Eingangssignalen des Entscheidungsbaumes und Stacking für die Fahrstreifenwechsel nach links und rechts.....	126
Abbildung 60: Leistungsfähigkeit des Regressionsbaumes in Bezug auf den zeitlichen Fehler der Prädiktion für Fahrstreifenwechsel nach links und rechts.....	127
Abbildung 61: Demonstratorfahrzeug Opel Insignia zur Integration des Algorithmus.....	129
Abbildung 62: Hardwarearchitektur der Fahrmanöverprädiktion im Demonstratorfahrzeug.....	130
Abbildung 63: Softwarearchitektur der Fahrmanöverprädiktion im Demonstratorfahrzeug.....	131
Abbildung 64: Visualisierung der Fahrmanöverprädiktion im Demonstratorfahrzeug.....	132
Abbildung 65: Darstellung der Visualisierung auf dem Infotainmentbildschirm in Echtzeit.....	133



---

## Tabellenverzeichnis

Tabelle 1: Fahrmanöverkatalog nach Dambier (2010).....	17
Tabelle 2: Ergebnisse der Fahrstreifenwechselprädiktion, Auszug aus Oliver und Pentland (2000) ....	19
Tabelle 3: Beispiel einer Wahrheitsmatrix .....	37
Tabelle 4: Vergleich von Vorgehensmodellen aus König (2012).....	42
Tabelle 5: Fahrerverhalten und Kopfrotation .....	59
Tabelle 6: Ablaufplan der Probandenstudie .....	66
Tabelle 7: Werte Kopfbewegungsdaten .....	81
Tabelle 8: Geeignete Prädiktoren der Kopfbewegungsdaten .....	82
Tabelle 9: Blickdaten .....	83
Tabelle 10: Werte decision stump von Fahrzeugdaten .....	84
Tabelle 11: Prädiktoren und Bewertung beim Fahrstreifenwechsel nach links .....	95
Tabelle 12: Variation der Designparameter des Algorithmus .....	112
Tabelle 13: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach links für n=9 Probandendatensätze mit Variation der Eingangssignale.....	117
Tabelle 14: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach rechts für n=9 Probandendatensätze der beiden besten Kombinationen von Eingangssignalen .....	118
Tabelle 15: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach links für n=32 Probandendatensätze der beiden besten Kombinationen von Eingangssignalen .....	119
Tabelle 16: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach rechts für n=32 Probandendatensätze der beiden besten Kombinationen von Eingangssignalen .....	119
Tabelle 17: Ergebnisse der Kreuzvalidierung des Fahrstreifenwechsels nach links für n=9 Probandendatensätze mit Daten der horizontalen Kopfrotation.....	121
Tabelle 18: Leistungsfähigkeit der gestackten Algorithmen des Fahrstreifenwechsels für n=32 Probandendatensätze im Vergleich zur Leistungsfähigkeit des Algorithmus ohne angeschlossenem Entscheidungs- und Regressionsbaum .....	128
Tabelle 19: Mittlere Rechenzeit der Algorithmen auf der Hardware im Demonstratorfahrzeug.....	133

---

## 2. Literaturverzeichnis

---

- Abendroth, B. (2001). *Gestaltungspotentiale für ein PKW-Abstandsregelsystem unter Berücksichtigung verschiedener Fahrertypen* (Bericht aus dem Institut für Arbeitswissenschaft der TU Darmstadt). ergonomia Verl.: Stuttgart.
- Achieser, I. (2016). *Potential evaluation of eye- and headtracking data as a robust and realtime capable predictor for driver intention detection and integration into an algorithm for maneuver prediction*. Master Thesis, Technische Universität Darmstadt. Darmstadt.
- Adamy, J. (2011). *Fuzzy Logik, neuronale Netze und evolutionäre Algorithmen* (Berichte aus der Steuerungs- und Regelungstechnik, 3. überarbeitete Auflage). Aachen.
- Aga, M. & Okada, A. (2003). Analysis of vehicle stability control (VSC)’s effectiveness from accident data. In *Proceedings of the 18 th ESV Conference, paper*.
- Ajzen, I. (1991). The theory of planned behavior. *Organizational behavior and human decision processes* 50 (2), 179–211.
- Anderson, J. R. (1993). *Rules of the mind*. Hillsdale, NJ: Lawrence Erlbaum Associates.
- Asteriadis, S., Karpouzis, K. & Kollias, S. (2014). Visual Focus of Attention in Non-calibrated Environments using Gaze Estimation. *International Journal of Computer Vision* 107 (3), 293–316.
- Bartels, A., Meinecke, M.-M. & Steinmeyer, S. (2015). Fahrstreifenwechselassistentz. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (S. 959–974). Wiesbaden: Springer Fachmedien Wiesbaden.
- Bascunana, J. L. (1995). Analysis of lane change crash avoidance. *SAE paper 951895*.
- Bauer, C. (2011). *A Driver-Specific Maneuver Prediction Model Based on Fuzzy Logic*. Dissertation, Freien Universität Berlin. Berlin.
- Bauer, F. (2016). *Ermittlung von Aktivitäten eines Fahrzeugführers während eines Fahrstreifenwechsels und möglicher Muster*. Masterthesis, Technische Universität Darmstadt. Darmstadt.
- Benda, H. von, Hoyos, K. G. & Schaible-Rapp, A. (1983). Klassifikation und Gefährlichkeit von Straßenverkehrssituationen. *Forschungsbericht BAST* (89).
- Bengler, K., Dietmayer, K., Färber, B., Maurer, M., Stiller, C. & Winner, H. (2014). Three Decades of Driver Assistance Systems. In *IEEE Intelligent Transportation Systems Magazine* 6(4), S. 6–22).
- Benmimoun, M., Fahrenkroq, F., Zlocki, A. & Eckstein, L. (2012). Erkennung und Klassifizierung kritischer Fahrsituationen mittels Fahrzeugdaten. *Automobiltechnische Zeitschrift*, 820–826.
- Berndt, H. & Dietmayer, K. (2009). Driver Intention Inference with Vehicle Onboard Sensors.
- Berndt, H., Emmert, J. & Dietmayer, K. (2008). Continuous Driver Intention Recognition with Hidden Markov Models. In *2008 11th International IEEE Conference on Intelligent Transportation Systems (ITSC)* (S. 1189–1194).
- Bernotat, R. (1970). Anthropotechnik in der Fahrzeugführung. In *Ergonomics* 13 (S. 353–377).
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. New York, NY 10013, USA: Springer Science+Business Media, LLC.
- Black, P. E. (2004). *Dictionary of algorithms and data structures*: National Institute of Standards and Technology.

- Blaschke, C., Schmitt, J. & Färber, B. (2007). Fahrmanöver-Prädiktion über CAN-Bus Daten. In VDI (Hrsg.), *Fahrer im 21. Jahrhundert. Human Machine Interface* (VDI-Berichte 2015, ). Düsseldorf: VDI-Verlag GmbH.
- Blaschke, C., Schmitt, J. & Färber, B. (2008). Überholmanöver-Prädiktion über CAN-Bus-Daten. *ATZ - Automobiltechnische Zeitschrift* 110 (11), 1022–1029.
- Boehm, B. (1986). *Wirtschaftliche Software-Produktion*. Wiesbaden: Forkel-Verl.
- Börger, J. (2012). *Fahrerintentionserkennung und Kursprädiktion mit erweiterten Maschinellen Lernverfahren*. Dissertation, Universität Ulm. Ulm.
- Bortz, J. & Schuster, C. (2010). *Statistik für Human- und Sozialwissenschaftler* (Springer-Lehrbuch, 7., vollst. überarb. und aktualisierte Aufl.). Heidelberg: Springer-Medizin-Verl.
- Breiman, L. (1996). Bagging predictors. *Machine learning* 24 (2), 123–140.
- Bruder, R., Abendroth, B. & Landau, K. (2007). Zum Nutzen von Fahrversuchen für die Gestaltung. In R. Bruder & H. Winner (Hrsg.), *Wie objektiv sind Fahrversuche* (S. 79–96). Stuttgart. <http://tubiblio.ulb.tu-darmstadt.de/43021/>.
- Bubb, H. (2002). Der Fahrprozess. Informationsverarbeitung durch den Fahrer. In Verband der Automobilindustrie (Hrsg.), *Technischer Kongress. Sicherheit durch Elektronik* (S. 19–31).
- Bunke, H. & Csirik, J. (1995). *Parametric String Edit Distance and its Application to Pattern Recognition*.
- Chovan, J. D. (1994). *Examination of lane change crashes and potential IVHS countermeasures*: National Highway Traffic Safety Administration.
- Chovan, J. D., Tijerina, L., Alexander, G. & Hendricks, D. L. (1994). *Examination of Lane Change Crashes and Potential IVHS Countermeasures*: National Highway Traffic Safety Administration.
- Chua, S.-L., Marsland, S. & Guesgen. (2011). Unsupervised learning of patterns in data streams using compression and edit distance. In *Proceedings of the Twenty-Second international joint conference on Artificial Intelligence* (Bd. 2, S. 1231).
- Condra, L. (2001). *Reliability Improvement With Design of Experiment*: CRC Press.
- Dambier, M. (2010). *Adaptive Information Flow Control. Recognition and Prediction of Factors Contributing to Driver's Stress*. Tönning, Lübeck und Marburg: Der andere Verlag.
- Damerau, F. J. (1964). A technique for computer detection and correction of spelling errors. *Communications of the ACM* 7 (3), 171–176. doi:10.1145/363958.363994
- Dang, T., Desens, J., Franke, U., Gavrila, D., Schäfers, L. & Ziegler, W. (2012). Steering and evasion assist. In *Handbook of intelligent vehicles* (S. 759–782). Springer.
- Destatis. (2015). *Verkehrsunfälle 2014* (Fachserie 8 Reihe 7). Wiesbaden: Statistisches Bundesamt.
- Diederichs, F. (2016). *Entwicklung von verhaltensbasierten Verfahren zur Erkennung von Fahrerintention für die Prädiktion von Fahrmanövern*. Dissertation, Universität Stuttgart. Stuttgart.
- Dietterich, T. G. (2002). Ensemble learning. *The handbook of brain theory and neural networks* 2, 110–125.
- DIN, 69901 (2009). *Projektmanagement - Projektmanagementsysteme*. Berlin: Beith Verlag.
- Ding, H., Trajcevski, G., Scheuermann, P., Wang, X. & Keogh, E. (2008). Querying and mining of time series data: experimental comparison of representations and distance measures. *Proceedings of the VLDB Endowment* 1 (2), 1542–1552.

- Domingos, P. (1999). The role of Occam's razor in knowledge discovery. *Data mining and knowledge discovery* 3 (4), 409–425.
- Donges, E. (1978). A Two-Level Model of Driver Steering Behaviour. *Human Factors* 6 (20), 691–707.
- Donges, E. (1982). Aspekte der Aktiven Sicherheit bei der Führung von Personenkraftwagen. *Automobil-Industrie* (2/82), 183–190.
- Donges, E. (2015). Fahrerverhaltensmodelle. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Doshi, A. & Trivedi, M. (2008). A comparative exploration of eye gaze and head motion cues for lane change intent prediction. In *2008 IEEE Intelligent Vehicles Symposium (IV)* (S. 49–54).
- Doshi, A. & Trivedi, M. (2009a). Investigating the relationships between gaze patterns, dynamic vehicle surround analysis, and driver intentions. *2009 IEEE Intelligent Vehicles Symposium (IV)*. IEEE. 2009, 887–92. Piscataway, NJ, USA. doi:10.1109/IVS.2009.5164397
- Doshi, A. & Trivedi, M. (2009b). Investigating the relationships between gaze patterns, dynamic vehicle surround analysis, and driver intentions. In *Intelligent Vehicles Symposium, 2009 IEEE* (S. 887–892).
- Doshi, A. & Trivedi, M. (2009c). On the Roles of Eye Gaze and Head Dynamics in Predicting Driver's Intent to Change Lanes. *Trans. Intell. Transport. Sys.* 10 (3), 453–462. <http://dx.doi.org/10.1109/TITS.2009.2026675>.
- Doshi, A. & Trivedi, M. M. (2011). Tactical driver behavior prediction and intent inference: A review. In *2011 14th International IEEE Conference on Intelligent Transportation Systems - (ITSC 2011)* (S. 1892–1897).
- Dosi, S. (2016). *Optimization and Further Development of an Algorithm for Driver Intention*. Optimization and further development of an algorithm for driver intention detection with Fuzzy Logic and Edit Distance. Masterthesis, Technischen Universität Chemnitz. Chemnitz.
- Duchowski, A. T. (2007). *Eye Tracking Methodology: Theory and Practice*. Secaucus, NJ, USA: Springer-Verlag New York, Inc.
- Egan, J. P. (1975). Signal detection theory and ROC analysis.
- Endsley, M. R. (1988). Design and evaluation for situation awareness enhancement. In *Proceedings of the Human Factors and Ergonomics Society Annual Meeting* (Bd. 32, S. 97–101).
- Endsley, M. R. (1995). Toward a theory of situation awareness in dynamic systems. *Human Factors: The Journal of the Human Factors and Ergonomics Society* 37 (1), 32–64.
- Engels, K. & Dellen, R. G. (1989). Der Einfluss von Suchfahrten auf das Unfallverursachungsrisiko. Eine Untersuchung über die Wirkung seelischer Stressoren auf das Unfallgeschehen. *Zeitschrift fuer Verkehrssicherheit* 35 (3).
- Enzweiler, M. & Gavril, D. M. (2009). Monocular pedestrian detection: Survey and experiments. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 31 (12), 2179–2195.
- Eurich, J. (2014). *Analyse des Blickverhaltens von Fahrzeugführern während verschiedener Notsituationen aus einer Probandenstudie*. Masterthesis, Technische Universität Darmstadt. Darmstadt.
- Euro NCAP (Euro NCAP, Hrsg.). (2016). European New Car Assessment Programme. [www.euroncap.com](http://www.euroncap.com). Zugriffen 20.04.2016.

- Färber, B. (2005). Erhöhter Fahrernutzen durch Integration von Fahrerassistenz- und Fahrerinformationssystemen. In *Fahrerassistenzsysteme mit maschineller Wahrnehmung* (S. 141–160). Springer.
- Fastenmeier, W. (1995). *Autofahrer und Verkehrssituation. Neue Wege zur Bewertung von Sicherheit und Zuverlässigkeit moderner Strassenverkehrssysteme* (Bd. 33).
- Fecher, N. & Hoffmann, J. (2015). Fahrerwarnelemente. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (S. 675–685). Wiesbaden: Springer Fachmedien Wiesbaden.
- Franz, B. (2014). *Entwicklung und Evaluation eines Interaktionskonzepts zur manöverbasierten Führung von Fahrzeugen*. Dissertation, Technische Universität Darmstadt. Darmstadt. <http://d-nb.info/1052431844/04>.
- Freund, Y. & Schapire, R. E. (Hrsg.). (1996). *Experiments with a new boosting algorithm* (Bd. 96).
- Fulcher, B. D. & Jones, N. S. (2014). Highly comparative feature-based time-series classification. *Knowledge and Data Engineering, IEEE Transactions on* 26 (12), 3026–3037.
- Gerdes, A. (2006). *Driving Manoeuvre Recognition*. Braunschweig: German Aerospace Center.
- Godthelp, H., Milgram, P. & Blaauw, G. J. (1984). The development of a time-related measure to describe driving strategy. *Human Factors: The Journal of the Human Factors and Ergonomics Society* 26 (3), 257–268.
- Gorrini, V. & Bersini, H. (1994). Recurrent fuzzy systems. In *Fuzzy Systems, 1994. IEEE World Congress on Computational Intelligence., Proceedings of the Third IEEE Conference on* (S. 193–198).
- Grabocka, J., Nanopoulos, A. & Schmidt-Thieme, L. (2012). Invariant time-series classification. In *Machine Learning and Knowledge Discovery in Databases* (S. 725–740). Springer.
- Gründl, M. (2002). Analyse des Fahrerverhaltens vor dem Unfall - eine Methode für eine verbesserte Fehleranalyse bei der Untersuchung realer Verkehrsunfälle. In *38. BDP- Kongress für Verkehrspsychologie Universität Regensburg*. Saarbrücken: Universitäts- und Landesbibliothek.
- Hamming, R. W. (1950). Error Detecting and Error Correcting Codes. *Bell System Technical Journal* 29 (2), 147–160. doi:10.1002/j.1538-7305.1950.tb00463.x
- Hecker, H. & Stapf, K. H. (1998). *Psychologisches Wörterbuch. 13., überarb. u. erw. Auflage*.
- Heckhausen, H. & Gollwitzer, P. M. (1987). Thought contents and cognitive functioning in motivational versus volitional states of mind. *Motivation and emotion* 11 (2), 101–120.
- Heide, W., Koenig, E., Trillenber, P., Kömpf, D. & Zee D.S. (1999). Electrooculography: technical standards and applications. *Recommendations for the Practice of Clinical Neurophysiology: Guidelines of the International Federation of Clinical Physiology*.
- Heine, J., Langer, I. & Schramm, T. (im Druck). Human Focused Development of a Manoeuvre Prediction in Urban Traffic Situations Based on Behavioural Sequences. In K. Bengler, J. Drüke, S. Hoffmann, D. Manstetten & A. Neukum (Hrsg.), *UR:BAN Human Factors in Traffic. Approaches for Safe, Efficient and Stress-free Urban Traffic* (S. 249–267). Springer Vieweg.
- Heine, J., Sylla, M., Schramm, T., Langer, I., Abendroth, B. & Bruder, R. (2015). Algorithm for Driver Intention Detection with Fuzzy Logic and Edit Distance. In *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on* (S. 1022–1027).

- Heine, J., Krämer, I., Achieser, I., Langer, I., Schramm, T. & Abendroth, B. (2015). Bewertung von Prädiktoren zur Fahrerintentionserkennung. In 5. Berliner Fachtagung Fahrermodellierung. Fahrermodelle in Wissenschaft und Wirtschaft. Berlin.
- Henning, M. (2004). *Indikatoren zur Fahrerabsichtserkennung - Das Blickverhalten bei Spurwechselvorgängen*. Diplomarbeit, Technischen Universität Chemnitz. Chemnitz.
- Henning, M. (2010a). *Preparation for lane change manoeuvres: Behavioural indicators and underlying cognitive processes*. Dissertation, Technischen Universität Chemnitz. Chemnitz.
- Henning, M. (2010b). *Preparation for Lane Change Manoeuvres: Behavioural Indicators and Underlying Cognitive Processes*.
- Henning, M., Georgeon, O., Dapzol, N. & Krems, J. (2009). *How Early can the Car Know That the Driver Would Like to Change Lanes? An Analysis of Early Indicators Selected by Underlying Cognitive Processes*.
- Heuser, S. (2013). *Development of a concept for a driving test in the context of a driver behavior prediction*. Studienarbeit, Technische Universität Darmstadt. Darmstadt.
- Hills, J., Lines, J., Baranauskas, E., Mapp, J. & Bagnall, A. (2014). Classification of time series by shapelet transformation. *Data mining and knowledge discovery* 28 (4), 851–881.
- Hoang, D. T. (1993). *Searching Genetic Databases on Splash 2*.
- Hoch, S. (2009, 01. Januar). *Kontextmanagement und Wissensanalyse im kognitiven Automobil der Zukunft*, Technische Universität München.
- Höfer, M. (2015). *Fahrerzustandsadaptive Assistenzfunktionen*. Dissertation, Universität Stuttgart. Stuttgart.
- Hoffmann, J. & Gayko, J. (2012). Fahrerwarnelemente. In H. Winner, S. Hakuli & G. Wolf (Hrsg.), *Handbuch Fahrerassistenzsysteme. Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort* (ATZ-MTZ-Fachbuch, 2., korr. Aufl, S. 343–354). Wiesbaden: Vieweg + Teubner.
- Hopstock, M. & Klanner, F. (2007). Kreuzungsassistenz-nur eine Vision? BMW Aktivitaeten fuer aktive und praeventive Sicherheit an Kreuzungen. *VDI-Berichte* (2013).
- Horprasert, T., Yacoob, Y. & Davis, L. S. (Hrsg.). (1997). *Computing 3D head orientation from a monocular image sequence*: International Society for Optics and Photonics.
- Hou, Y., Edara, P. & Sun, C. (2014). Modeling mandatory lane changing using Bayes classifier and decision trees. *Intelligent Transportation Systems, IEEE Transactions on* 15 (2), 647–655.
- Huang, J., Shao, X. & Wechsler, H. (Hrsg.). (1998). *Face pose discrimination using support vector machines (SVM)* (Bd. 1): IEEE.
- Hühnhagen, T., Dengler, I., Tamke, A., Dang, T. & Breuel, G. (2010). Maneuver recognition using probabilistic finite-state machines and fuzzy logic. In *2010 IEEE Intelligent Vehicles Symposium (IV)* (S. 65–70).
- INVENT (INVENT-Büro, Hrsg.). (2005). INVENT „erfahren“ – mobil mit 8 Sinnen. Ergebnisbericht. <http://www.tuvpt.de/fileadmin/pdf/INVENT-Ergebnisse.pdf>. Zugriffen 26.09.2016.
- Ishida, S. & Gayko, J. E. (2004). Development, evaluation and introduction of a lane keeping assistance system. In *Intelligent Vehicles Symposium, 2004 IEEE* (S. 943–944).
- ISO, 26262 (2011). *ISO 26262: Road Vehicles - Functional Safety*.

- Juang, C.-F. (2002). A TSK-type recurrent fuzzy network for dynamic systems processing by neural network and genetic algorithms. *Fuzzy Systems, IEEE Transactions on* 10 (2), 155–170.
- Kahlert, J. (1995). Fuzzy Control für Ingenieure. Vieweg, Braunschweig/Wiesbaden.
- Kasper, D., Weidl, G., Dang, T., Breuel, G., Tamke, A., Wedel, A. & Rosenstiel, W. (2012). Object-Oriented Bayesian Networks for Detection of Lane Change Maneuvers. *IEEE Intelligent Transportation Systems Magazine* 4 (3), 19–31. doi:10.1109/MITS.2012.2203229
- Kobiela, F. (2012). *Fahrerintentionserkennung für autonome Notbremssysteme*. Dissertation, Technischen Universität Dresden. Dresden.
- König, C. (2012). *Analyse und Anwendung eines menschenzentrierten Gestaltungsprozesses zur Entwicklung von Human-Machine-Interfaces im Arbeitskontext am Beispiel Flugsicherung*. Dissertation, Technische Universität Darmstadt. Darmstadt. <http://tuprints.ulb.tu-darmstadt.de/3208/>
- Kopf, M. (2005). Was nützt es dem Fahrer, wenn Fahrerinformations- und -assistenzsysteme etwas über ihn wissen? In M. Maurer & C. Stiller (Hrsg.), *Fahrerassistenzsysteme mit maschineller Wahrnehmung*. basiert auf ausgewählten Vorträgen eines Workshops in Walting (Altmühltal) (S. 117–139). Berlin: Springer.
- Kretschmer, M., König, L., Neubeck, J. & Wiedemann, J. (2006). Erkennung und Prädiktion des Fahrerhaltens während eines Überholvorgangs. In 2. Tagung Aktive Sicherheit durch Fahrerassistenz. München. Zugriffen 19.10.2012.
- Krüger, H. P. (2008). Hedonomie–die emotionale Dimension der Fahrerassistenz. *Aktive Sicherheit durch Fahrerassistenz, München*.
- Kruse, R., Gebhardt, J. & Klawonn, J. (1994). *Fuzzy Systeme* (2. Auflage).
- Kuge, N., Yamamura, T. & Shimoyama, O. (2000). A Driver Behavior Recognition Method Based on a Driver Model Framework.
- Langer, I., Heine, J., Abendroth, B. & Bruder, R. (2014). Herausforderungen beim Hervorrufen von kritischen Brems- oder Lenkreaktionen in Fahrversuchen zur Untersuchung der Fahrerintention. In GfA (Hrsg.), *Gestaltung der Arbeitswelt der Zukunft. 60. Kongress der Gesellschaft für Arbeitswissenschaft* (S. 516–519). Dortmund: GfA Press.
- Langer, I. (2016). *Analyse von Aktivitäten eines Fahrzeugführers zur Verhaltensbeschreibung am Beispiel des Fahrstreifenwechsels*. Dissertation, Technische Universität Darmstadt. Darmstadt.
- Langer, I., Holzheimer, F., Heine, J., Abendroth, B. & Bruder, R. (2015). Development and partial validation of a catalogue of action steps for a car driver. In *Proceedings 19th Triennial Congress of the IEA*. <http://tubiblio.ulb.tu-darmstadt.de/76155/>.
- Langer, I., Abendroth, B. & Bruder, R. (2016, 08. März). *Bericht zu UR:BAN VIE. Prädiktion von Fahrer-Verhaltensmustern in ausgewählten Situationen*. IAD-Nr. OP3UB1 (Institut für Arbeitswissenschaft, Hrsg.).
- Laplace, P.-S. (1951). A Philosophical Essay on Probabilities:. In P. Simon, M. de Laplace, F. W. Truscott & F. L. Emory (Hrsg.), *A philosophical essay on probabilities* (Bd. 166). Dover Publications.
- Lee, H. & Cho, S. (2003). PCA+HMM+SVM for EEG pattern classification. In *Signal Processing and Its Applications, 2003. Proceedings. Seventh International Symposium on* (Bd. 1, S. 541–544).
- Lee, S. E., Olsen, E. C. B. & Wierwille, W. W. (2004). *A comprehensive examination of naturalistic lane changes*. Washington, DC: NHTSA.

- Lee, S. E., Wierwille, W. W. & Olden, E. (2004). *A Comprehensive Examination of Naturalistic Lane Changes*: National Highway Traffic Safety Administration.
- Lethaus, F. & Rataj, J. (2007). Do eye movements reflect driving manoeuvres? In *IET Intelligent Transport Systems* (Bd. 1, S. 199).
- Levensthein, V. I. (1966). Binary Codes Capable of Correcting Deletions, Insertions and Reversals. *Soviet Physics Doklady*, 10, S. 707–710.
- Levesque, A. & Johrendt, J. (2011). The State of the Art of Driver Model Development. In *SAE 2011 World Congress & Exhibition* (SAE TECHNICAL PAPER SERIES ). SAE International, 400 Commonwealth Drive, Warrendale, PA, United States.
- Liebner, M., Klanner, F. & Stiller, C. (2012). Der Fahrer im Mittelpunkt – Eye-Tracking als Schlüssel zum mitdenkenden Fahrzeug?
- Liebner, M., Klanner, F., Baumann, M., Ruhhammer, C. & Stiller, C. (2013). Velocity-based driver intent inference at urban intersections in the presence of preceding vehicles. *Intelligent Transportation Systems Magazine, IEEE* 5 (2), 10–21.
- Liu, A. & Salvucci, D. (2001). Modeling and Prediction of Human Driver Behavior. In *Proc. of the 9th Intl Conference on Human-Computer Interaction*, (New Orleans (LA), USA, S. 1479–1483).
- Lorenz, L. M. (2014, 01. Januar). *Entwicklung und Bewertung aufmerksamkeitslenkender Warn- und Informationskonzepte für Fahrerassistenzsysteme. Aufmerksamkeitssteuerung in der frühen Phase kritischer Verkehrssituationen*. Dissertation, Technische Universität München. München. <http://nbn-resolving.de/urn:nbn:de:bvb:91-diss-20140516-1160623-0-7>.
- Luczak, H. (1975). *Untersuchungen informatorischer Belastung und Beanspruchung des Menschen* (Fortschrittberichte der VDI-Zeitschriften Reihe 10, Angewandte Informatik, elektronische Datenverarbeitung, Nr. 2). Düsseldorf: VDI-Verlag.
- Manstetten, D., Bengler, K., Busch, F., Färber, B., Lehsing, C., Neukum, A., Petermann-Stock, I. & Schendzielorz, T. (2013). “UR: BAN MV Human Factors in Traffic”-a German Research Project to Increase Safety in Urban Traffic. In *20th ITS World Congress*.
- Maurer, M. (2012). Forward collision warning and avoidance. In *Handbook of Intelligent Vehicles* (S. 657–687). Springer.
- McCall, J. C., Wipf, D. P., Trivedi, M. M. & Rao, B. D. (2005). Lane Change Intent Analysis Using Robust Operators and Sparse Bayesian Learning.
- McCall, J. C., Wipf, D. P., Trivedi, M. M. & Rao, B. D. (2007). Lane Change Intent Analysis Using Robust Operators and Sparse Bayesian Learning. In *IEEE transactions on intelligent transportation systems. No.3* (Bd. 8, Bd. 8, S. 431–440).
- McKnight, A. J. & Adams, B. B. (1970). Driver Education Task Analysis. Volume I: Task Descriptions. Final Report (August 1969-July 1970).
- Meitinger, K.-H. (2008). *Top-down-Entwicklung von aktiven Sicherheitssystemen für Kreuzungen*. Dissertation, Technische Universität München. München.
- Metz, C. E. (1978). Basic principles of ROC analysis. In *Seminars in nuclear medicine* (Bd. 8, S. 283–298).
- Morris, B., Doshi, A. & Trivedi, M. (2011). Lane change intent prediction for driver assistance: On-road design and evaluation. In *Intelligent Vehicles Symposium (IV), 2011 IEEE* (S. 895–901).



- Mourant, R. R. & Donohue, R. J. (1977). Acquisition of indirect information by novice, experienced, and mature drivers. *Journal of safety research*.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*: MIT Press.
- Murphy-Chutorian, E., Doshi, A. & Trivedi, M. M. (2007). Head pose estimation for driver assistance systems: A robust algorithm and experimental evaluation. In *IEEE Intelligent Transport Systems Conference*.
- Nabati, M. & Behrad, A. (2010). Robust facial 2D motion model estimation for 3D head pose extraction and automatic camera mouse implementation. In *Telecommunications (IST), 2010 5th International Symposium on* (S. 817–824).
- Nagel, H. & Enkelmann, W. (1991). *Generic road traffic situations and driver support systems*.
- Naujoks, F., Grattenthaler, H. & Neukum, A. (2012). Zeitliche Gestaltung effektiver Fahrerinformationen zur Kollisionsvermeidung auf der Basis kooperativer Perzeption. In *8. Workshop FAS*.
- Navarro, G. (2001). A guided tour to approximate string matching. *ACM Computing Surveys* 33 (1), 31–88. doi:10.1145/375360.375365
- Niyogi, S. & Freeman, W. T. (1996). Example-based head tracking. In *Automatic Face and Gesture Recognition, 1996., Proceedings of the Second International Conference on* (S. 374–378).
- Noll, G. (2015). *Performance of Driving Tests and Analysis of the Objective Data of Longitudinal Guidance Maneuver*. Masterthesis, Technische Universität Darmstadt. Darmstadt.
- Nyström, M. & Holmqvist, K. (2010). An adaptive algorithm for fixation, saccade, and glissade detection in eyetracking data. *Behavior Research Methods* 42 (1), 188–204. <http://dx.doi.org/10.3758/BRM.42.1.188>.
- Ohn-Bar, E., Tawari, A., Martin, S. & Trivedi, M. M. (2014). Predicting driver maneuvers by learning holistic features. In *Intelligent Vehicles Symposium Proceedings, 2014 IEEE* (S. 719–724).
- Oliver, N. & Pentland, A. P. (2000). Driver behavior recognition and prediction in a SmartCar. In *AeroSense 2000* (S. 280–290).
- Olsen, E. (2003). *Modeling slow lead vehicle lane changing*. Dissertation, Virginia Polytechnic Institute and State University. Blacksburg.
- Olsen, E., Lee, S. & Wierwille, W. (2005). Eye Glance Behavior During Lane Changes and Straight-Ahead Driving. *Transportation Research Record*. <http://www-us.ebsco.com/online/direct.asp?AccessToken=>.
- Pech, T., Lindner, P. & Wanielik, G. (2014). Head tracking based glance area estimation for driver behaviour modelling during lane change execution. In *Intelligent Transportation Systems (ITSC), 2014 IEEE 17th International Conference on* (S. 655–660).
- Pentland, A. & Liu, A. (1999). Modeling and prediction of human behavior. *Neural computation*, S. 229–242.
- Poitschke, T. M. (2011). Blickbasierte Mensch-Maschine Interaktion im Automobil.
- Polling, D., Mulder, M., van Paassen, M. M. & Chu, Q. P. (2005). Inferring the driver's lane change intention using context-based Dynamic Bayesian Networks. In *Proceedings of IEEE International Conference on Systems, Man and Cybernetics* (S. 853–858).
- Posner, M. I. & Rafal, R. D. (1987). Cognitive theories of attention and the rehabilitation of attentional deficits.

- Rakotonirainy, A. (2005). Context-aware driver's behaviour model. In *19th International Technical Conference on the Enhanced Safety of Vehicles ESV'19*.
- Rasmussen, J. (1983). Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *Systems, Man and Cybernetics, IEEE Transactions on* (3), 257–266.
- Risse, H.-J. (1991). *Das Fahrerverhalten bei normaler Fahrzeugführung* (VDI-Fortschrittsbericht Reihe 12, Bd. 160). Düsseldorf: VDI Verlag.
- Rodemerck, C. (2011). *Analyse und Entwicklung von Bewertungsmaßstäben für die Kritikalität von Fahrsituationen*. Master Thesis, Technische Universität Darmstadt. Darmstadt.
- Rodriguez, J. J. & Kuncheva, L. I. (2007). Time series classification: Decision forests and SVM on interval and DTW features. In *Proc. of the Workshop and Challenge on Time Series Classification*.
- Rohmert, W. (1984). Das Belastungs-Beanspruchungs-Konzept. *Zeitschrift für Arbeitswissenschaft* 38 (4), 193–200.
- Royce, W. W. (1970). Managing the development of large software systems. In *proceedings of IEEE WESCON* (Bd. 26, S. 1–9).
- Sahin, H. (2015). *Performance of Driving Tests and Analysis of the Objective Data of Lateral Guidance Maneuver*, Technische Universität Darmstadt. Darmstadt.
- Saint-Mont, U. (2011). *Statistik im Forschungsprozess: eine Philosophie der Statistik als Baustein einer integrativen Wissenschaftstheorie*: Springer-Verlag.
- Salvador, S. & Chan, P. (2007). Toward accurate dynamic time warping in linear time and space. *Intelligent Data Analysis* 11 (5), 561–580.
- Salvucci, D. D. & Goldberg, J. H. (2000). Identifying Fixations and Saccades in Eye-tracking Protocols. In *Proceedings of the 2000 Symposium on Eye Tracking Research & Applications* (ETRA '00, S. 71–78). New York, NY, USA: ACM. <http://doi.acm.org/10.1145/355017.355028>.
- Salvucci, D. D. & Gray, R. (2004). A two-point visual control model of steering. *Perception* 33 (10), 1233–1248. doi:10.1068/p5343
- Salvucci, D. D., Mandalia, H. M., Kuge, N. & Yamamura, T. (2007). Lane-change detection using a computational driver model. *HUMAN FACTORS* 49 (3), 532–542. doi:10.1518/001872007X200157
- Schapire, R. E., Rochery, M., Rahim, M. & Gupta, N. (Hrsg.). (2002). *Incorporating prior knowledge into boosting* (Bd. 2).
- Schiefler, L. (2015). Club Elo. Version 3. [www.clubelo.com](http://www.clubelo.com). Zugegriffen 12.04.2016.
- Schildger, D. (2014). *Analyse von Ergebnissen einer Probandenstudie zur Untersuchung des Fahrerverhaltens und Weiterentwicklung des Studiendesigns*. Bachelorthesis, Technische Universität Darmstadt. Darmstadt.
- Schmidt, K., Beggiato, M., Hoffmann, K. H. & Krems, J. F. (2014). A mathematical model for predicting lane changes using the steering wheel angle. *Journal of safety research* 49, 85–90.
- Schneider, J. H. (2009). *Modellierung und Erkennung von Fahrsituationen und Fahrmanövern für sicherheitsrelevante Fahrerassistenzsysteme*. Dissertation, Techn. Univ. Chemnitz. <http://nbn-resolving.de/urn:nbn:de:bsz:ch1-qucosa-61500>.
- Schroven, F. & Giebel, T. (2008). Fahrerintentionserkennung fuer Fahrerassistenzsysteme / Driver intent recognition for advanced driver assistance systems. *VDI-Berichte* (2048).

- Sherrah, J., Gong, S. & Ong, E. J. (2001). Face distributions in similarity space under varying head pose. *Image and Vision Computing* 19 (12), 807–819. <http://www.sciencedirect.com/science/article/pii/S0262885600000962>.
- Smart Eye AB. (2015). Smart Eye Pro. <http://smarteye.se/>. Zugegriffen 25.10.2015.
- Smart Eye AB. (2016). Smart Eye Pro. <http://smarteye.se/research-instruments/se-pro/>. Zugegriffen 13.02.2017.
- Sommer, M. (2016). *Ermittlung von Aktivitäten eines Fahrzeugführers während eines Fahrstreifenwechsels und möglicher Muster*. Masterthesis, Technische Universität Darmstadt. Darmstadt.
- Statistisches Bundesamt. (2016). *Zahl der Verkehrstoten 2015 um 2,9 % gestiegen*. Wiesbaden.
- Stiefelhagen, R. & Zhu, J. (2002). Head Orientation and Gaze Direction in Meetings. In *Proceedings of CHI '02*.
- Sylla, M. (2015). *Entwicklung eines Algorithmus zur Fahrmanöverprädiktion mit Methoden der Fuzzy-Logik*. Masterthesis, TU Darmstadt. Darmstadt.
- Takahashi, A. & Akamatsu, M. (2008). *Statistical Characteristics of Backward Glancing while Natural Driving on Expressway*.
- Tijerina, L., Garrott, W., Stoltzfus, D. & Parmer, E. (2005). Eye Glance Behavior of Van and Passenger Car Drivers During Lane Change Decision Phase. *Transportation Research Record: Journal of the Transportation Research Board* 1937, 37–43.
- Tingvall, C. & Haworth, N. (1999). Vision Zero - An ethical approach to safety and mobility. In *6th ITE International Conference Road Safety & Traffic Enforcement*. Melbourne.
- Tölle, W. (1996). Ein Fahrmanöverkonzept für einen maschinellen Kopiloten. *Fortschritt Berichte-VDI Reihe 12: Verkehrstechnik, Fahrzeugtechnik*.
- Trefflich, B. (2010). *Videogestützte Überwachung der Fahreraufmerksamkeit und Adaption von Fahrerassistenzsystemen*. Dissertation, Techn. Univ. Ilmenau. urn://nbn:de:gbv:ilm1-2010000039.
- Trivedi, M. M., Gandhi, T. & McCall, J. (2007). Looking-in and looking-out of a vehicle: Computer-vision-based enhanced vehicle safety. *Intelligent Transportation Systems, IEEE Transactions on* 8 (1), 108–120.
- van Zanten, A. & Kost, F. (2012). Bremsenbasierte Assistenzfunktionen. In H. Winner, S. Hakuli & G. Wolf (Hrsg.), *Handbuch Fahrerassistenzsysteme. Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort* (ATZ-MTZ-Fachbuch, 2., korr. Aufl. ). Wiesbaden: Vieweg + Teubner.
- Wakasugi, T. (2005). A study on warning timing for lane change decision aid systems based on driver's lane change maneuver. In *Proc. 19th International Technical Conference on the Enhanced Safety of Vehicles, Paper*.
- Winner, H. (2012). Adaptive cruise control. In H. Winner, S. Hakuli & G. Wolf (Hrsg.), *Handbuch Fahrerassistenzsysteme. Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort* (ATZ-MTZ-Fachbuch, 2., korr. Aufl. ). Wiesbaden: Vieweg + Teubner.
- Winner, H., Hakuli, S., Lotz, F. & Singer, C. (2015). *Handbuch Fahrerassistenzsysteme. Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort* (ATZ/MTZ-Fachbuch, 3., überarbeitete und ergänzte Auflage).
- Wolpert, D. H. & Macready, W. G. (1996). *No free lunch theorems for search*. : Technical Report SFI-TR-95-02-010, Santa Fe Institute.

- 
- Xi, X., Keogh, E., Shelton, C., Wei, L. & Ratanamahatana, C. A. (2006). Fast time series classification using numerosity reduction. In *Proceedings of the 23rd international conference on Machine learning* (S. 1033–1040).
- Xiao, J., Moriyama, T., Kanade, T. & Cohn, J. F. (2003). Robust full-motion recovery of head by dynamic templates and re-registration techniques. *International Journal of Imaging Systems and Technology* 13 (1), 85–94.
- Xing, Z., Pei, J. & Keogh, E. (2010). A brief survey on sequence classification. *ACM SIGKDD Explorations Newsletter* 12 (1), 40–48.
- Xing, Z., Pei, J. & Philip, S. Y. (2012). Early classification on time series. *Knowledge and information systems* 31 (1), 105–127.
- Ye, L. & Keogh, E. (2009). Time series shapelets: a new primitive for data mining. In *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining* (S. 947–956).
- Zadeh, L. A. (1965). Fuzzy sets. *Information and control* 8 (3), 338–353.
- Zeyrek, G. (2014). *Durchführung von Fahrversuchen und Auswertung der Blickbewegungsdaten*. Bachelorthesis, Technische Universität Darmstadt. Darmstadt.
- Zhao, H. & Liu, Z. (2009). Shape-Based Human Activity Recognition Using Edit Distance. In *IEEE Image and Signal Processing CISP '09*.
- Zwerschke, S. (2006). Untersuchung zu Bekanntheit, Akzeptanz und Kaufinteresse von Fahrerassistenzsystemen/Study on awareness, acceptance and willingness to buy of driver assistance systems. *VDI-Berichte* (Nr. 1960).